

ΕΛΛΗΝΙΚΟ ΜΕΣΟΓΕΙΑΚΟ ΠΑΝΕΠΙΣΤΗΜΙΟ

ΣΧΟΛΗ ΕΠΙΣΤΗΜΩΝ ΔΙΟΙΚΗΣΗΣ ΚΑΙ ΟΙΚΟΝΟΜΙΑΣ

ΤΜΗΜΑ ΔΙΟΙΚΗΤΙΚΗΣ ΕΠΙΣΤΗΜΗΣ ΚΑΙ ΤΕΧΝΟΛΟΓΙΑΣ

ΕΦΑΡΜΟΓΗ ΤΩΝ RECOMMENDER SYSTEMS ΣΤΙΣ ΕΠΙΧΕΙΡΗΣΕΙΣ

ΠΤΥΧΙΑΚΗ ΕΡΓΑΣΙΑ

Εισηγητής: Πολυξένη Τσέρου, Α.Μ. 252

Επιβλέπων: Δρ. Κωνσταντίνος Παναγιωτάκης, Καθηγητής

©

2026

HELLENIC MEDITERRANEAN UNIVERSITY

SCHOOL OF MANAGEMENT AND ECONOMICS SCIENCE

DEPARTMENT OF MANAGEMENT SCIENCE AND TECHNOLOGY

APPLICATION OF RECOMMENDER SYSTEMS IN BUSINESS

DIPLOMA THESIS

Student : Polixeni Tserou, A.M. 252

Supervisor: Dr. Costas Panagiotakis, Professor

©

2026

Υπεύθυνη Δήλωση *: Βεβαιώνω ότι είμαι συγγραφέας αυτής της πτυχιακής εργασίας και ότι κάθε βοήθεια την οποία είχα για την προετοιμασία της, είναι πλήρως αναγνωρισμένη και αναφέρεται στην πτυχιακή εργασία. Επίσης έχω αναφέρει τις όποιες πηγές από τις οποίες έκανα χρήση δεδομένων, ιδεών ή λέξεων, είτε αυτές αναφέρονται ακριβώς είτε παραφρασμένες. Επίσης βεβαιώνω ότι αυτή η πτυχιακή εργασία προετοιμάστηκε από εμένα προσωπικά ειδικά για τις απαιτήσεις του προγράμματος σπουδών του Τμήματος Διοικητικής Επιστήμης και Τεχνολογίας του ΕΛ.ΜΕ.ΠΑ.*

ΠΕΡΙΛΗΨΗ

Η ραγδαία ψηφιοποίηση έχει καταστήσει τα συστήματα συστάσεων (Recommender Systems – RS) κρίσιμο μηχανισμό εξατομίκευσης και υποστήριξης αποφάσεων. Η παρούσα εργασία διερευνά τον ρόλο τους στο σύγχρονο επιχειρηματικό περιβάλλον, συνδυάζοντας βιβλιογραφική ανασκόπηση και συγκριτική ανάλυση επιλεγμένων μελετών περίπτωσης από τον διεθνή και τον ελληνικό χώρο (Amazon, Netflix, Spotify, Tripadvisor, Skroutz, e-food, Public.gr). Στο θεωρητικό μέρος αναλύονται οι βασικές κατηγορίες RS, οι κύριες μετρικές αξιολόγησης και κρίσιμες προκλήσεις όπως η ψυχρή εκκίνηση και η μεροληψία. Στο τεχνολογικό μέρος παρουσιάζονται σύγχρονες τάσεις (βαθιά μάθηση, μεγάλα γλωσσικά μοντέλα, συνομιλιακά συστήματα). Το εφαρμοσμένο μέρος εξετάζει κάθε πλατφόρμα με κριτήρια την μορφή προσωποποίησης, τα τεκμηριωμένα τεχνικά στοιχεία και τα επιχειρησιακά οφέλη, ενώ όπου οι τεχνικές λεπτομέρειες δεν είναι δημόσια διαθέσιμες, η ανάλυση παραμένει ενδεικτική. Τα ευρήματα αναδεικνύουν ότι η στρατηγική αξιοποίηση των RS μπορεί να αποτελέσει παράγοντα διαφοροποίησης, ακόμη και σε αγορές μικρότερης κλίμακας όπως η ελληνική, υπό την προϋπόθεση της προσαρμογής στις τοπικές ιδιαιτερότητες. Τέλος, διατυπώνονται προτάσεις για μελλοντική έρευνα με έμφαση στην ενσωμάτωση σύγχρονης AI, την ανάπτυξη διαφανών συστημάτων και τη δημιουργία προσαρμοσμένων λύσεων για την ελληνική αγορά.

Λέξεις-κλειδιά: Συστήματα συστάσεων, ηλεκτρονικό εμπόριο, εξατομίκευση, μηχανική μάθηση, τεχνητή νοημοσύνη, μελέτες περίπτωσης, ελληνική αγορά

ABSTRACT

The rapid digitalization of everyday life has established Recommender Systems (RS) as a critical mechanism for personalization and decision support. This study examines their role in the contemporary business environment by combining a literature review with a comparative analysis of selected case studies from both the international and Greek markets (Amazon, Netflix, Spotify, Tripadvisor, Skroutz, e-food, Public.gr). The theoretical part analyzes the main categories of RS, key evaluation metrics, and critical challenges such as cold start and bias. The technological section presents modern trends (deep learning, large language models, conversational systems). The applied part examines each platform based on criteria including the form of personalization, the documented technical details, and the business benefits; where technical specificities are not publicly available, the analysis remains indicative. The findings indicate that the strategic utilization of RS can act as a differentiating factor, even in smaller-scale markets such as Greece, provided they are adapted to local specificities. Finally, recommendations for future research are proposed, with an emphasis on the integration of modern AI, the development of transparent and interpretable systems, and the creation of customized, cost-effective solutions for the Greek market.

Keywords: Recommender Systems, e-commerce, personalization, machine learning, artificial intelligence, case studies, Greek market

ΠΙΝΑΚΑΣ ΠΕΡΙΕΧΟΜΕΝΩΝ

ΛΙΣΤΑ ΠΙΝΑΚΩΝ vii
ΛΙΣΤΑ ΣΧΕΔΙΑΓΡΑΜΜΑΤΩΝ viii
ΛΙΣΤΑ ΕΙΚΟΝΩΝ ix
ΣΥΝΤΟΜΟΓΡΑΦΙΕΣ x
ΕΥΧΑΡΙΣΤΙΕΣ xi
1. ΚΕΦΑΛΑΙΟ 1: ΕΙΣΑΓΩΓΗ 1
1.1. Το ψηφιακό περιβάλλον και η ανάγκη για συστάσεις 1
1.2. Τα Recommender Systems και η σημασία τους στις επιχειρήσεις 2
1.3. Σκοπός, στόχοι και ερευνητικά ερωτήματα 3
1.4. Μεθοδολογία και δομή της εργασίας 4
2. ΚΕΦΑΛΑΙΟ 2: Θεωρητικό Πλαίσιο Συστημάτων Συστάσεων 7
2.1. Ορισμός Και Λειτουργία Των Recommender Systems 7
2.2. Κατηγορίες Συστημάτων Συστάσεων 11
2.2.1. Συνεργατικό Φιλτράρισμα (Collaborative Filtering) 12
2.2.2. Φιλτράρισμα Βάσει Περιεχομένου (Content-Based Filtering) 14
2.2.3. Υβριδικά Μοντέλα (Hybrid Recommender Systems) 15
2.3. Μέτρα Απόδοσης και Αξιολόγησης 18
2.3.1. Μετρικές κατάταξης: Precision, Recall και F1 19
2.3.2. Μετρικές σφάλματος πρόβλεψης: MAE και RMSE 20
2.3.3. Επιχειρηματικές μετρικές απόδοσης 22
2.4. Προκλήσεις και Περιορισμοί των Συστημάτων Συστάσεων 23
2.4.1. Πρόβλημα ψυχρής εκκίνησης (Cold Start) 23
2.4.2. Αραιότητα δεδομένων (Data Sparsity) 25
2.4.3. Μεροληψία (Bias) 25
2.4.4. Επεκτασιμότητα και υπολογιστική πολυπλοκότητα 27
2.4.5. Ιδιωτικότητα και προστασία δεδομένων 27
3. ΚΕΦΑΛΑΙΟ 3: Επιχειρησιακή Αξία των Recommender Systems 28
3.1. Ο Ρόλος των Recommender Systems στο Επιχειρηματικό Μοντέλο 28

3.2. Επιρροή των Recommender Systems στην Αγοραστική Εμπειρία 30
3.3. Ενίσχυση Πωλήσεων και Προσωποποίηση Υπηρεσιών 32
3.4. Εμπορικά Οφέλη: Διατήρηση Πελατών, Upselling και Cross-Selling 34
3.5. Πιθανοί Κίνδυνοι – Λάθος Προτάσεις και Απώλεια Εμπιστοσύνης 37
4. ΚΕΦΑΛΑΙΟ 4: Σύγχρονες Τεχνολογικές Τάσεις και AI στα Recommender Systems ... 42
4.1. Τεχνητή Νοημοσύνη και Recommender Systems 42
4.2. Απλές Τεχνικές Μηχανικής Μάθησης 44
4.2.1. Matrix Factorization 45
4.2.2. Clustering (K-Means) 46
4.2.3. Βασικά Στοιχεία Deep Learning 48
4.3. Ενίσχυση Αλγορίθμων μέσω Τεχνητής Νοημοσύνης 49
4.4. Παραδείγματα Εργαλείων Recommender Systems 51
4.5. Μελλοντικές Εξελίξεις (LLMs, Conversational Recommender Systems) 53
5. ΚΕΦΑΛΑΙΟ 5: Μελέτη Περίπτωσης – Amazon & Netflix 58
5.1. Εταιρικό Προφίλ, Στρατηγική και Προκλήσεις Προσωποποίησης 58
5.2. Χρήση των Recommender Systems στην Εμπειρία Χρήστη 61
5.3. Τεχνολογική Προσέγγιση (Τύποι Συστάσεων και Αλγόριθμοι) 64
5.4. Επιχειρησιακά Αποτελέσματα 66
5.5. Σύνοψη και Ανάλυση Επιτυχίας 70
6. ΚΕΦΑΛΑΙΟ 6: Μελέτη Περίπτωσης – Spotify & Tripadvisor 73
6.1. Εξατομίκευση στην Ψυχαγωγία και στον Τουρισμό 73
6.2. Πώς Λειτουργούν τα Recommender Systems σε Τεχνικό Επίπεδο 80
6.3. Εμπειρία Χρήστη και Στρατηγική Engagement 82
6.4. Ανάλυση Πλεονεκτημάτων και Προκλήσεων 86
7. ΚΕΦΑΛΑΙΟ 7: Μελέτη Περίπτωσης στην Ελληνική Αγορά 91
7.1. Skroutz: Συνδυασμός RS με Φίλτρα και Αγοραστική Συμπεριφορά 91
7.2. E-food: Real-Time Συστάσεις με Βάση την Περιοχή 96

7.3. Public.gr: Απλές Μορφές Συστάσεων Βάσει Προφίλ 101
7.4. Περιορισμοί Ελληνικής Αγοράς (Υποδομές, Προσωπικά Δεδομένα) 108
8. ΚΕΦΑΛΑΙΟ 8: Συμπεράσματα και Προτάσεις 113
8.1. Ανακεφαλαίωση Κύριων Σημείων 113
8.2. Απαντήσεις στα Ερευνητικά Ερωτήματα 114
8.3. Επιπτώσεις για τις Επιχειρήσεις 115
8.4. Περιορισμοί της Παρούσας Μελέτης 117
8.5. Προτάσεις για Μελλοντική Έρευνα και Βελτίωση 118
ΒΙΒΛΙΟΓΡΑΦΙΑ 121
Α. ΞΕΝΟΓΛΩΣΣΗ 121
Β. ΕΛΛΗΝΙΚΗ 126

ΛΙΣΤΑ ΠΙΝΑΚΩΝ

Πίνακας 2. 1 : Σύγκριση κατηγοριών συστημάτων συστάσεων 18
Πίνακας 2. 2 Βασικές μετρικές αξιολόγησης συστημάτων συστάσεων 20
Πίνακας 5. 1 Σύγκριση τεχνολογικής προσέγγισης Amazon vs Netflix 66
Πίνακας 5. 2: Οφέλη Χρήσης RS σε Amazon και Netflix. 69
Πίνακας 5. 3 Συγκριτική ανάλυση επιτυχίας Amazon – Netflix 71
Πίνακας 6. 1 Σύγκριση των τεχνικών προσεγγίσεων μεταξύ Spotify και Tripadvisor 81
Πίνακας 6. 2 Σύγκριση στρατηγικών engagement μεταξύ Spotify και Tripadvisor 85
Πίνακας 6. 3 Σύγκριση τεχνικών προσεγγίσεων (εξατομίκευση) Spotify vs Tripadvisor 87
Πίνακας 6. 4 Σύγκριση στρατηγικών engagement Spotify vs Tripadvisor 87
Πίνακας 6. 5 Πλεονεκτήματα και προκλήσεις Spotify vs Tripadvisor 90
Πίνακας 7 1 Συνδυασμός φίλτρων και RS στο Skroutz 91
Πίνακας 7 2 Real-time δεδομένα στο e-food και επίδραση στις προτάσεις 99
Πίνακας 7 3: Διαφοροποίηση e-food από e-commerce και streaming 100
Πίνακας 7 4 Δεδομένα που αξιοποιούνται Public.gr 102
Πίνακας 7 5 Μορφές Προσωποποίησης κατηγοριών Public 104
Πίνακας 7 6 Content-based vs Collaborative Filtering στο Public.gr 105
Πίνακας 7 7 Τα οφέλη της απλούστερης προσέγγισης 106
Πίνακας 7 8 Σύγκριση Public.gr με Amazon / Netflix 107
Πίνακας 7 9 Συνοπτικός πίνακας περιορισμών ελληνικής αγοράς 110
Πίνακας 7 10 Συγκριτική επισκόπηση μελετών περίπτωσης βάσει κοινών κριτηρίων 112
Πίνακας 8 1 Συνοπτικός πίνακας επιπτώσεων RS για επιχειρήσεις 116
Πίνακας 8 2 Συνοπτικός πίνακας περιορισμών μελέτης 118
Πίνακας 8 3 Συνοπτικός πίνακας προτάσεων για μελλοντική έρευνα (με προτεραιότητες) . 120

ΛΙΣΤΑ ΣΧΕΔΙΑΓΡΑΜΜΑΤΩΝ

Σχεδιάγραμμα 2. 1 8
Σχεδιάγραμμα 2. 2 10
Σχεδιάγραμμα 2. 3 13
Σχεδιάγραμμα 2. 4 15
Σχεδιάγραμμα 2. 5 16
Σχεδιάγραμμα 2. 6 24
Σχεδιάγραμμα 3. 1 30
Σχεδιάγραμμα 3. 2 35
Σχεδιάγραμμα 3. 3 36
Σχεδιάγραμμα 3. 4 39
Σχεδιάγραμμα 4. 1 46
Σχεδιάγραμμα 4. 2 48
Σχεδιάγραμμα 4. 3 55
Σχεδιάγραμμα 5. 1 68

ΛΙΣΤΑ ΕΙΚΟΝΩΝ

Εικόνα 5. 1 59
Εικόνα 5. 2 60
Εικόνα 5. 3 60
Εικόνα 6. 1 74
Εικόνα 6. 2 74
Εικόνα 6. 3 75
Εικόνα 6. 4 75
Εικόνα 6. 5 75
Εικόνα 6. 6 77
Εικόνα 6. 7 77
Εικόνα 6. 8 78
Εικόνα 6. 9 78
Εικόνα 6. 10 79
Εικόνα 7. 1 92
Εικόνα 7. 2 93
Εικόνα 7. 3 94
Εικόνα 7. 4 95
Εικόνα 7. 5: 97
Εικόνα 7. 6 98
Εικόνα 7. 7 102
Εικόνα 7. 8 103
Εικόνα 7. 9 103

ΣΥΝΤΟΜΟΓΡΑΦΙΕΣ

Συντομογραφία	Πλήρης όρος (Ελληνικά)	Πλήρης όρος (Αγγλικά)
AI	Τεχνητή Νοημοσύνη	Artificial Intelligence
AOV	Μέση Αξία Συναλλαγής	Average Order Value
CF	Συνεργατικό Φιλτράρισμα	Collaborative Filtering
CBF	Φιλτράρισμα Βάσει Περιεχομένου	Content-Based Filtering
CRS	Συνομιλιακό Σύστημα Συστάσεων	Conversational Recommender System
GDPR	Γενικός Κανονισμός Προστασίας Δεδομένων	General Data Protection Regulation
GNN	Νευρωνικό Δίκτυο Γράφου	Graph Neural Network
GPS	Παγκόσμιο Σύστημα Εντοπισμού Θέσης	Global Positioning System
KPI	Βασικός Δείκτης Απόδοσης	Key Performance Indicator
LLM	Μεγάλο Γλωσσικό Μοντέλο	Large Language Model
MAE	Μέσο Απόλυτο Σφάλμα	Mean Absolute Error
ML	Μηχανική Μάθηση	Machine Learning
NLP	Επεξεργασία Φυσικής Γλώσσας	Natural Language Processing
POI	Σημείο Ενδιαφέροντος	Point of Interest
RMSE	Ρίζα Μέσου Τετραγωνικού Σφάλματος	Root Mean Square Error
RS	Σύστημα Συστάσεων	Recommender System
SKU	Μονάδα Διατήρησης Αποθέματος	Stock Keeping Unit
XRS	Ερμηνεύσιμο Σύστημα Συστάσεων	Explainable Recommender System

ΕΥΧΑΡΙΣΤΙΕΣ

Με την ολοκλήρωση της παρούσας πτυχιακής εργασίας, θα ήθελα να εκφράσω τις θερμές μου ευχαριστίες σε όσους στάθηκαν δίπλα μου σε αυτό το ταξίδι.

Πρώτα απ' όλα, ευχαριστώ μέσα από την καρδιά μου τους γονείς μου, Δήμο και Σοφία,όπως και τις αδερφές μου,Κων/να και Ελένη, που υπήρξαν πάντα το στήριγμά μου, πιστεύοντας σε μένα και ενθαρρύνοντάς με σε κάθε βήμα. Ένα μεγάλο ευχαριστώ στον σύζυγό μου, Μενέλαο, και στα παιδιά μου, Σοφία και Μιχάλη, που έδειξαν απέραντη υπομονή και κατανόηση όλους αυτούς τους μήνες, στηρίζοντας την προσπάθειά μου με αγάπη και χαμόγελα.

Ιδιαίτερες ευχαριστίες οφείλω στον επιβλέποντα καθηγητή μου, Δρ. Κωνσταντίνο Παναγιωτάκη, για την πολύτιμη καθοδήγηση, την υποστήριξη και την εμπιστοσύνη του. Η βοήθειά του υπήρξε καθοριστική για την ολοκλήρωση αυτής της εργασίας και την εκπλήρωση ενός ονείρου που, έστω και καθυστερημένα, γίνεται πραγματικότητα.

1. ΚΕΦΑΛΑΙΟ 1: ΕΙΣΑΓΩΓΗ

1.1. Το ψηφιακό περιβάλλον και η ανάγκη για συστάσεις

Η έντονη ψηφιοποίηση της καθημερινής ζωής έχει δημιουργήσει ένα περιβάλλον στο οποίο οι καταναλωτές έρχονται συχνά αντιμέτωποι με έναν εξαιρετικά μεγάλο αριθμό επιλογών. Η πληθώρα αυτή πληροφοριών και εναλλακτικών μπορεί να δυσκολεύει τη διαδικασία λήψης αποφάσεων, οδηγώντας σε αυτό που στη βιβλιογραφία αναφέρεται ως «παράλυση της επιλογής». Όπως επισημαίνουν οι Bollen et al. (2010), ο μεγάλος όγκος διαθέσιμης πληροφορίας δεν διευκολύνει πάντοτε τον χρήστη. Αντίθετα, μπορεί να προκαλέσει γνωστική κόπωση και να οδηγήσει σε λιγότερο αποτελεσματικές ή μη επαρκείς αποφάσεις. Αντίστοιχα, οι Resnick και Varian (1997), καθώς και οι Deldjoo et al. (2020), υπογραμμίζουν ότι η αναζήτηση των πιο σχετικών και χρήσιμων επιλογών γίνεται ολοένα και πιο απαιτητική, τόσο για τους ίδιους τους χρήστες όσο και για τις επιχειρήσεις που προσπαθούν να ανταποκριθούν στις ανάγκες τους.

Μέσα σε αυτό το πλαίσιο, τα συστήματα συστάσεων (Recommender Systems – RS) αποκτούν ιδιαίτερη σημασία. Σύμφωνα με τους Adomavicius και Tuzhilin (2005), τα συστήματα αυτά λειτουργούν ως μηχανισμοί πλοήγησης και εξατομίκευσης, καθώς βοηθούν τους χρήστες να εντοπίζουν προϊόντα, υπηρεσίες ή περιεχόμενο που συνδέονται περισσότερο με τις πραγματικές ανάγκες, τα ενδιαφέροντα και τις προτιμήσεις τους. Η δυνατότητα γρήγορης και αποτελεσματικής πρόσβασης σε σχετικές επιλογές θεωρείται καθοριστικός παράγοντας για τη βελτίωση της εμπειρίας χρήστη (Bobadilla et al., 2013, Lu et al., 2015). Παράλληλα, οι Pu, Chen και Hu (2012) τονίζουν ότι όταν οι προτάσεις είναι στοχευμένες και ουσιαστικές, μειώνεται η γνωστική επιβάρυνση του χρήστη και ενισχύεται η συνολική του ικανοποίηση. Σε αυτό το περιβάλλον υπερπληθώρας δεδομένων, τα συστήματα συστάσεων λειτουργούν ουσιαστικά ως «αόρατοι επιμελητές» της καθημερινότητάς μας, φιλτράροντας τον τεράστιο όγκο πληροφοριών και καθορίζοντας σε μεγάλο βαθμό την ψηφιακή μας εμπειρία (Resnick & Varian, 1997· Bollen et al., 2010).

Η ανάγκη αξιοποίησης των συστημάτων συστάσεων δεν σχετίζεται μόνο με τον αυξανόμενο όγκο της πληροφορίας, αλλά και με τη δυναμική και διαρκώς μεταβαλλόμενη φύση του ψηφιακού περιβάλλοντος. Οι σύγχρονοι χρήστες αλληλοεπιδρούν καθημερινά με

περιεχόμενο μέσα από διαφορετικές πλατφόρμες, εφαρμογές και συσκευές, γεγονός που καθιστά ακόμη πιο σημαντική την ύπαρξη μηχανισμών που υποστηρίζουν και απλοποιούν τη διαδικασία επιλογής. Υπό αυτή την έννοια, τα συστήματα συστάσεων δεν αποτελούν απλώς ένα τεχνολογικό εργαλείο, αλλά μια βασική υποδομή για τη βελτίωση της αγοραστικής εμπειρίας, την ενίσχυση της εξατομίκευσης και τη διατήρηση της ανταγωνιστικότητας των επιχειρήσεων στη σύγχρονη ψηφιακή οικονομία.

1.2. Τα Recommender Systems και η σημασία τους στις επιχειρήσεις

Τα συστήματα συστάσεων αποτελούν πλέον έναν από τους βασικούς μηχανισμούς λειτουργίας της ψηφιακής οικονομίας. Όπως αναφέρουν οι Bobadilla et al. (2013) και οι Jannach και Jugovac (2019), η συμβολή τους δεν περιορίζεται μόνο στην τεχνική υποστήριξη της αναζήτησης ή της επιλογής προϊόντων. Αντίθετα, επηρεάζουν ουσιαστικά τον τρόπο με τον οποίο διαμορφώνεται η σχέση ανάμεσα στην επιχείρηση και τον πελάτη. Η συναλλαγή παύει να είναι απλώς μια τυπική διαδικασία αγοράς και μετατρέπεται σε μια περισσότερο εξατομικευμένη εμπειρία, η οποία μπορεί να ενισχύσει τη δέσμευση του χρήστη και τη μακροπρόθεσμη αξία του για την επιχείρηση. Μέσα από την αξιοποίηση δεδομένων που σχετίζονται με τη συμπεριφορά, τις προτιμήσεις και τις προηγούμενες επιλογές των χρηστών, τα συστήματα συστάσεων δίνουν στις επιχειρήσεις τη δυνατότητα να προσαρμόζουν με πιο δυναμικό τρόπο τα προϊόντα, τις υπηρεσίες και την επικοινωνία τους.

Παράλληλα, η χρήση αλγοριθμικών μοντέλων και η ανάλυση δεδομένων συμπεριφοράς επιτρέπουν στις επιχειρήσεις να προτείνουν προϊόντα ή υπηρεσίες που έχουν μεγαλύτερη πιθανότητα να ανταποκριθούν στις ανάγκες και τα ενδιαφέροντα του κάθε χρήστη. Με τον τρόπο αυτό, ενισχύεται η αποτελεσματικότητα των εμπορικών στρατηγικών και βελτιώνεται η σύνδεση ανάμεσα στην προσφορά της επιχείρησης και στη ζήτηση του καταναλωτή (Alamdari et al., 2020). Σύμφωνα με τους Schafer et al. (2001), η προσωποποίηση που προσφέρουν τα συστήματα συστάσεων μπορεί να οδηγήσει σε υψηλότερα ποσοστά μετατροπής (conversion rates), καθώς ο χρήστης εκτίθεται σε επιλογές που είναι πιο σχετικές με τις ανάγκες του. Ταυτόχρονα, η συνεχής παροχή κατάλληλου και εξατομικευμένου περιεχομένου συμβάλλει στην αύξηση της δέσμευσης των χρηστών, στη μεγαλύτερη διάρκεια παραμονής τους στις ψηφιακές πλατφόρμες και, κατ’ επέκταση, στην ενίσχυση των εσόδων των επιχειρήσεων (Jannach & Jugovac, 2019).

Στο ευρύτερο πλαίσιο του ψηφιακού μετασχηματισμού, η ενσωμάτωση συστημάτων συστάσεων δεν μπορεί να θεωρηθεί απλώς μια τεχνολογική καινοτομία. Αντιθέτως, αποτελεί μια στρατηγική επιχειρηματική επιλογή, καθώς συνδέεται άμεσα με την εμπειρία του πελάτη, την αποτελεσματικότητα των πωλήσεων και τη δυνατότητα των επιχειρήσεων να διαφοροποιούνται σε ένα ιδιαίτερα ανταγωνιστικό περιβάλλον. Σε μια περίοδο όπου οι καταναλωτές αναμένουν όλο και περισσότερο εξατομικευμένες εμπειρίες, η αξιοποίηση των συστημάτων συστάσεων αποτελεί ουσιαστική προϋπόθεση για τις επιχειρήσεις που επιδιώκουν να παραμείνουν ανταγωνιστικές στη σύγχρονη ψηφιακή οικονομία.

1.3. Σκοπός, στόχοι και ερευνητικά ερωτήματα

Η παρούσα εργασία έχει ως αντικείμενο τη μελέτη της λειτουργίας, των τεχνολογικών εξελίξεων και των επιχειρησιακών εφαρμογών των συστημάτων συστάσεων. Βασικός άξονας της ανάλυσης είναι η ανάδειξη του ρόλου τους στην υποστήριξη της λήψης αποφάσεων και στη βελτίωση της εμπειρίας των χρηστών σε διαφορετικούς επιχειρησιακούς τομείς. Ιδιαίτερη έμφαση δίνεται στον κλάδο του ηλεκτρονικού εμπορίου, καθώς αποτελεί ένα από τα πεδία στα οποία τα συστήματα συστάσεων έχουν γνωρίσει ιδιαίτερα μεγάλη διείσδυση και πρακτική αξιοποίηση. Στο πλαίσιο αυτό, εξετάζεται η σύνδεσή τους με σύγχρονες τεχνολογικές εξελίξεις, όπως η τεχνητή νοημοσύνη και τα γραφήματα (graphs), οι οποίες επηρεάζουν σημαντικά τον τρόπο με τον οποίο αναπτύσσονται και εφαρμόζονται τα σύγχρονα RS.

Οι ειδικότεροι στόχοι της εργασίας είναι οι εξής:

1. Η αποσαφήνιση των βασικών εννοιών, κατηγοριών και μεθοδολογιών που διέπουν τα RS.
2. Η επισκόπηση των σύγχρονων τεχνολογικών τάσεων, με έμφαση στην τεχνητή νοημοσύνη και τις υβριδικές προσεγγίσεις.
3. Η παρουσίαση παραδειγμάτων επιτυχημένων εφαρμογών συστημάτων συστάσεων, τόσο σε διεθνές όσο και σε ελληνικό επίπεδο, μέσα από περιπτώσεις όπως η Amazon, το Netflix, το Skroutz κ.ά.

4. Η ανάλυση των βασικών προκλήσεων και περιορισμών που αντιμετωπίζουν τα συστήματα συστάσεων κατά την πρακτική εφαρμογή τους, λαμβάνοντας υπόψη τεχνικές, ηθικές και οικονομικές διαστάσεις.
5. Η διατύπωση προτάσεων και κατευθύνσεων για την αξιοποίηση των συστημάτων συστάσεων σε μελλοντικά επιχειρησιακά μοντέλα και στρατηγικές.

Με βάση τους παραπάνω στόχους, η εργασία επιχειρεί να απαντήσει στα ακόλουθα ερευνητικά ερωτήματα:

• Πώς ενσωματώνονται τα recommender systems στις επιχειρησιακές διαδικασίες και ποιες είναι οι επιπτώσεις τους στην απόδοση των επιχειρήσεων;

• Ποια είναι τα βασικά πλεονεκτήματα και μειονεκτήματα των διαφορετικών κατηγοριών συστημάτων συστάσεων;

• Ποιες τεχνολογικές τάσεις διαμορφώνουν το μέλλον των recommender systems και πώς επηρεάζουν τη χρήση τους στο ηλεκτρονικό εμπόριο;

• Ποιες πρακτικές εφαρμογές των συστημάτων συστάσεων εντοπίζονται σε διεθνές και ελληνικό επίπεδο και ποια συμπεράσματα μπορούν να εξαχθούν σχετικά με την αποτελεσματικότητά τους;

Η διερεύνηση των παραπάνω ερωτημάτων αναμένεται να συμβάλει στην καλύτερη κατανόηση του τρόπου με τον οποίο τα συστήματα συστάσεων επηρεάζουν τις σύγχρονες επιχειρησιακές πρακτικές και, παράλληλα, μετασχηματίζουν την καταναλωτική εμπειρία στη σημερινή ψηφιακή εποχή.

1.4.Μεθοδολογία και δομή της εργασίας

Η παρούσα εργασία βασίζεται σε βιβλιογραφική ανασκόπηση (literature review) και δευτερογενή ανάλυση δεδομένων. Η ερευνητική προσέγγιση είναι κυρίως ποιοτική, καθώς επικεντρώνεται στην κατανόηση των τεχνολογιών, των μεθόδων και των επιπτώσεων των recommender systems, μέσα από την ανάλυση επιστημονικών άρθρων, ερευνητικών δημοσιεύσεων και πραγματικών εφαρμογών.

Η εργασία στηρίχθηκε σε σύγχρονες και έγκυρες διεθνείς πηγές, οι οποίες επιλέχθηκαν με κριτήρια την επιστημονική εγκυρότητα, την επικαιρότητα και τη συνάφεια με το αντικείμενο.

Η ανάλυση περιλαμβάνει τέσσερα σκέλη:

1. Θεωρητική προσέγγιση των βασικών εννοιών και αλγορίθμων των RS.
2. Συγκριτική μελέτη διαφορετικών τεχνικών και μοντέλων.
3. Εξέταση πραγματικών εφαρμογών μέσω μελετών περίπτωσης (case studies).
4. Αξιολόγηση των επιχειρησιακών επιπτώσεων και των σχετικών προκλήσεων.

Η συγκριτική διάσταση διατρέχει το σύνολο της εργασίας, καθώς οι μελέτες περίπτωσης αναλύονται βάσει κοινών κριτηρίων (επιχειρησιακό πλαίσιο, μορφή προσωποποίησης, τεχνική λογική, επιχειρησιακά οφέλη και κίνδυνοι, επίπεδο τεκμηρίωσης), επιτρέποντας τη συστηματική αντιπαραβολή τόσο μεταξύ διεθνών και ελληνικών πλατφορμών όσο και μεταξύ διαφορετικών κλάδων

Η δομή της εργασίας έχει διαμορφωθεί έτσι ώστε να εξασφαλίζεται ομαλή μετάβαση από τη θεωρία στην πράξη:

- Κεφάλαιο 1: Παρουσιάζει το γενικό πλαίσιο της έρευνας, την ανάγκη για συστήματα συστάσεων, καθώς και τον σκοπό και τα ερευνητικά ερωτήματα.
- Κεφάλαιο 2: Αναλύει το θεωρητικό υπόβαθρο των RS, τις βασικές κατηγορίες και τα μέτρα αξιολόγησης.
- Κεφάλαιο 3: Εστιάζει στην επιχειρησιακή αξία των RS και στη συμβολή τους στη βελτίωση της εμπειρίας πελάτη.
- Κεφάλαιο 4: Παρουσιάζει τις σύγχρονες τεχνολογικές τάσεις και τον ρόλο της τεχνητής νοημοσύνης.
- Κεφάλαια 5–7: Περιλαμβάνουν μελέτες περίπτωσης από διεθνές και ελληνικό επίπεδο.
- Κεφάλαιο 8: Συνοψίζει τα βασικά συμπεράσματα και διατυπώνει προτάσεις για μελλοντική έρευνα.

Η εργασία εστιάζει σε συγκεκριμένους κλάδους (ηλεκτρονικό εμπόριο, streaming, τουρισμός, food delivery) λόγω της έντονης χρήσης RS σε αυτούς, αναγνωρίζοντας ότι τα συμπεράσματα μπορεί να μην είναι πλήρως γενικεύσιμα σε άλλους τομείς όπως η υγεία ή η εκπαίδευση. Επιπλέον, η ανάλυση επικεντρώνεται στις τεχνικές και επιχειρησιακές διαστάσεις των RS, αφήνοντας μια πιο ενδελεχή διερεύνηση των κοινωνικών και ηθικών προεκτάσεων για μελλοντική έρευνα. Η αναζήτηση της βιβλιογραφίας πραγματοποιήθηκε σε ακαδημαϊκές βάσεις δεδομένων (όπως Google Scholar, Scopus και IEEE Xplore) και επίσημες εταιρικές πηγές, με έμφαση σε υλικό που δημοσιεύτηκε κυρίως από το 2000 και εξής, συμπεριλαμβανομένων και θεμελιωδών παλαιότερων εργασιών, ώστε να καλυφθεί

τόσο η κλασική θεωρία όσο και οι σύγχρονες τάσεις. Οι μελέτες περίπτωσης επιλέχθηκαν σκόπιμα ώστε να αντιπροσωπεύουν διαφορετικούς κλάδους (e-commerce, streaming, τουρισμός, food delivery) και διαφορετικά επίπεδα διαθέσιμης τεχνικής τεκμηρίωσης (από πλήρως τεκμηριωμένα διεθνή συστήματα έως ελληνικά παραδείγματα με ανάλυση βασισμένη σε δημόσια διαθέσιμες πληροφορίες), επιτρέποντας μια ρεαλιστική συγκριτική αξιολόγηση.

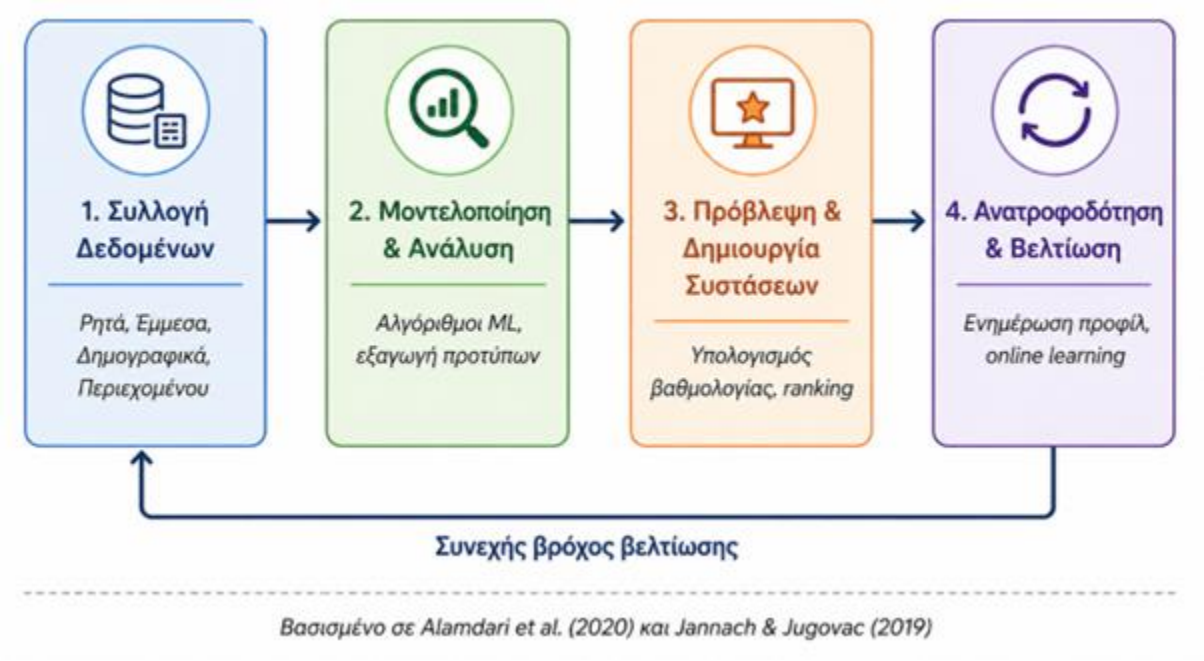
2. ΚΕΦΑΛΑΙΟ 2: Θεωρητικό Πλαίσιο Συστημάτων Συστάσεων

2.1. Ορισμός Και Λειτουργία Των Recommender Systems

Τα συστήματα συστάσεων (Recommender Systems - RS) εντάσσονται στην ευρύτερη κατηγορία των εξειδικευμένων πληροφοριακών συστημάτων. Ο βασικός τους σκοπός είναι να παρέχουν στους χρήστες εξατομικευμένες προτάσεις, αξιοποιώντας δεδομένα που σχετίζονται με τις προτιμήσεις, τη συμπεριφορά και τα ιδιαίτερα χαρακτηριστικά τους. Όπως επισημαίνουν οι Resnick και Varian (1997), καθώς και οι Ricci et al. (2010), η ανάπτυξη των συστημάτων αυτών συνδέεται άμεσα με την ανάγκη αποτελεσματικής διαχείρισης του πολύ μεγάλου όγκου πληροφορίας που χαρακτηρίζει το σύγχρονο ψηφιακό περιβάλλον.

Στη διεθνή βιβλιογραφία, ένα recommender system ορίζεται συχνά ως ένα σύστημα που έχει τη δυνατότητα να «προβλέπει την αξιολόγηση ή την προτίμηση ενός χρήστη για ένα αντικείμενο» και, με βάση αυτή την πρόβλεψη, να προτείνει τα αντικείμενα που θεωρούνται καταλληλότερα για τον συγκεκριμένο χρήστη (Adomavicius & Tuzhilin, 2005). Τα αντικείμενα αυτά μπορεί να αφορούν προϊόντα, υπηρεσίες, ψηφιακό περιεχόμενο ή ακόμη και τουριστικούς προορισμούς, ανάλογα με το πεδίο εφαρμογής του συστήματος (Ricci et al. 2010).

Η λειτουργία των RS βασίζεται στη συλλογή, την επεξεργασία και την ανάλυση δεδομένων που αφορούν τόσο τους χρήστες όσο και τα προτεινόμενα αντικείμενα. Σύμφωνα με τους Alamdari et al. (2020) και τους Jannach και Jugovac (2019), ένα τυπικό σύστημα συστάσεων περιλαμβάνει τέσσερα βασικά στάδια, τα οποία παρουσιάζονται στη συνέχεια, στο Σχεδιάγραμμα 2.1.



Σχεδιάγραμμα 2. 1

Τα τέσσερα βασικά στάδια λειτουργίας ενός συστήματος συστάσεων. Η διαδικασία είναι κυκλική, με την ανατροφοδότηση να οδηγεί σε συνεχή βελτίωση.

Συλλογή δεδομένων: Τα συστήματα συστάσεων συλλέγουν δεδομένα από διαφορετικές πηγές, με σκοπό τη δημιουργία μιας όσο το δυνατόν πληρέστερης εικόνας για τον χρήστη και τα αντικείμενα που πρόκειται να προταθούν. Όπως αναφέρουν οι Alamdari et al. (2020) και οι Jannach και Jugovac (2019), τα δεδομένα αυτά μπορούν να διακριθούν σε ρητά δεδομένα, όπως αξιολογήσεις και βαθμολογίες, έμμεσα δεδομένα, όπως clicks και ιστορικό αγορών, δημογραφικά δεδομένα, όπως ηλικία, φύλο και τοποθεσία, καθώς και δεδομένα περιεχομένου, τα οποία αφορούν τα χαρακτηριστικά των προϊόντων ή των υπηρεσιών. Ο συνδυασμός ρητών και έμμεσων δεδομένων θεωρείται ιδιαίτερα σημαντικός, καθώς επιτρέπει τη διαμόρφωση ενός πιο ολοκληρωμένου και αξιόπιστου προφίλ χρήστη.

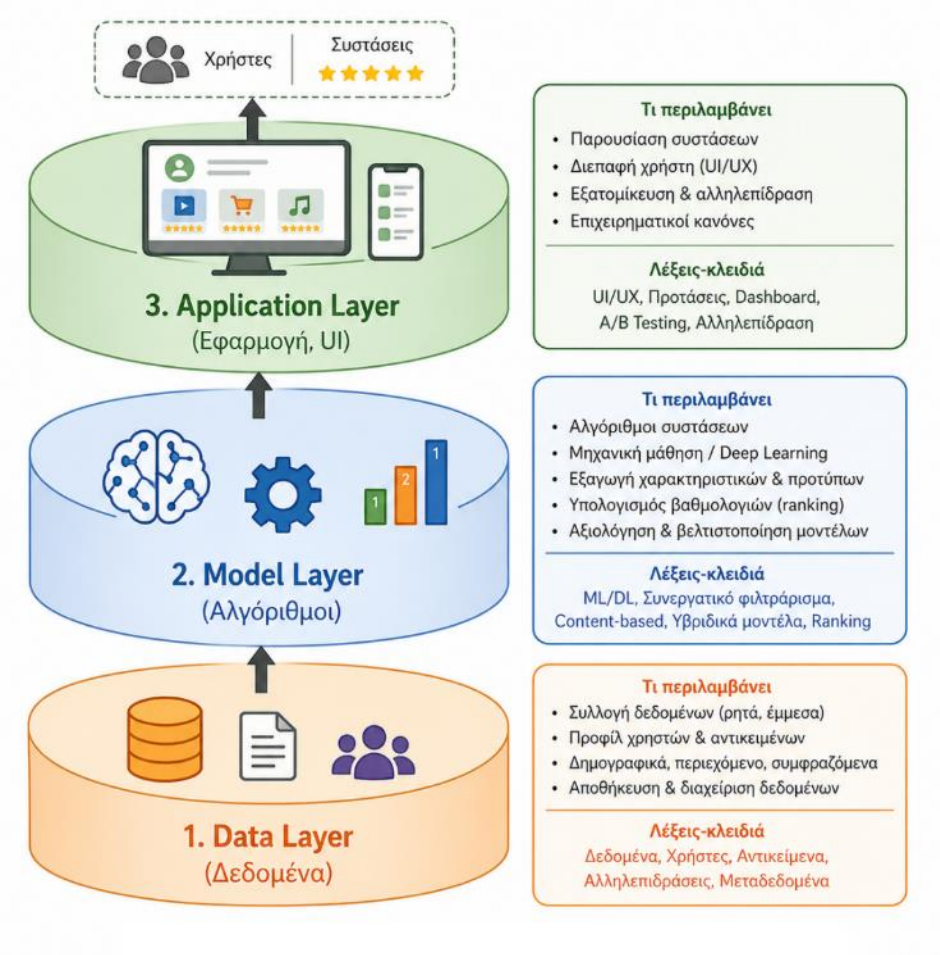
Μοντελοποίηση και ανάλυση δεδομένων: Στο στάδιο αυτό, τα δεδομένα που έχουν συλλεχθεί επεξεργάζονται και αναλύονται μέσω αλγορίθμων μηχανικής μάθησης, με στόχο την αναγνώριση προτύπων, ομοιοτήτων και συσχετίσεων. Σύμφωνα με τους Papadakis et al. (2022), τα μοντέλα αυτά επιχειρούν ουσιαστικά να απαντήσουν στο ερώτημα: «Τι είναι πιθανό να ενδιαφέρει τον συγκεκριμένο χρήστη;». Οι βασικές προσεγγίσεις περιλαμβάνουν την αναγνώριση ομοιοτήτων μεταξύ χρηστών, την ανάλυση των χαρακτηριστικών των αντικειμένων και την εξαγωγή λανθανουσών σχέσεων μέσα από μαθηματικά και στατιστικά

μοντέλα. Η διαδικασία αυτή συνδέεται στενά με την Εξόρυξη Δεδομένων (Data Mining), η οποία επιτρέπει την ανακάλυψη γνώσης και μοτίβων από μεγάλους όγκους δεδομένων, τροφοδοτώντας τους αλγορίθμους με χρήσιμα χαρακτηριστικά (features) για την παραγωγή προβλέψεων.

Πρόβλεψη και δημιουργία συστάσεων: Με βάση το εκπαιδευμένο μοντέλο, το σύστημα υπολογίζει μια εκτιμώμενη βαθμολογία προτίμησης για κάθε αντικείμενο. Στη συνέχεια, δημιουργεί μια ταξινομημένη λίστα προτάσεων (ranking), στην οποία εμφανίζονται τα αντικείμενα που θεωρούνται πιο σχετικά ή πιο πιθανό να ενδιαφέ-ρουν τον χρήστη. Οι προτάσεις αυτές παρουσιάζονται στον χρήστη με στόχο να βελτιώσουν την εμπειρία του, να μειώσουν την προσπάθεια αναζήτησης και να υποστηρίξουν αποτελεσματικότερα τη διαδικασία λήψης αποφάσεων.

Ανατροφοδότηση και συνεχής βελτίωση: Τα συστήματα συστάσεων δεν λειτουργούν με στατικό τρόπο, αλλά εξελίσσονται διαρκώς μέσα από τη νέα πληροφορία που προκύπτει από τις αλληλεπιδράσεις των χρηστών. Όπως σημειώνουν οι Alamdari et al. (2020), κάθε νέα ενέργεια του χρήστη, όπως μια αγορά, ένα click, μια αξιολόγηση ή ακόμα και η παραμονή σε συγκεκριμένο περιεχόμενο, μπορεί να αξιοποιηθεί για την ενημέρωση του προφίλ του. Με αυτόν τον τρόπο, το σύστημα βελτιώνει σταδιακά το μοντέλο του και αυξάνει την ακρίβεια των μελλοντικών συστάσεων.

Σε επίπεδο αρχιτεκτονικής, ένα recommender system οργανώνεται συνήθως σε τρία βασικά επίπεδα, όπως απεικονίζεται στο Σχεδιάγραμμα 2.2. Το πρώτο είναι το επίπεδο δεδομένων (Data Layer), στο οποίο πραγματοποιείται η αποθήκευση, η οργάνωση και η διαχείριση των δεδομένων που αφορούν τους χρήστες και τα αντικείμενα. Το δεύτερο είναι το επίπεδο μοντέλου (Model Layer), όπου εφαρμόζονται οι κατάλληλοι αλγόριθμοι, εκπαιδεύονται τα μοντέλα και παράγονται οι προβλέψεις. Το τρίτο είναι το επίπεδο εφαρμογής (Application Layer), μέσα από το οποίο οι συστάσεις παρουσιάζονται τελικά στον χρήστη με τρόπο λειτουργικό και κατανοητό (Ricci et al. 2010).



Σχεδιάγραμμα 2. 2

Η αρχιτεκτονική τριών επιπέδων ενός συστήματος συστάσεων. Το επίπεδο δεδομένων τροφοδοτεί το επίπεδο μοντέλου, το οποίο με τη σειρά του παράγει τις προτάσεις στο επίπεδο εφαρμογής. *Προσαρμογή από Προσαρμογή από Ricci et al. (2010).*

Τα τελευταία χρόνια, η λειτουργία των συστημάτων συστάσεων έχει εξελιχθεί σημαντικά, κυρίως λόγω της ενσωμάτωσης προηγμένων τεχνολογιών τεχνητής νοημοσύνης. Όπως επισημαίνουν οι Gao et al. (2023), ιδιαίτερο ενδιαφέρον παρουσιάζουν τα Graph Neural Networks (GNNs), καθώς επιτρέπουν τη μοντελοποίηση σύνθετων σχέσεων μεταξύ χρηστών και αντικειμένων μέσα από τη χρήση γράφων (graphs). Σε αυτή τη δομή, οι κόμβοι μπορούν να αντιπροσωπεύουν χρήστες ή αντικείμενα, ενώ οι ακμές αποτυπώνουν τις μεταξύ τους αλληλεπιδράσεις.

Με αυτόν τον τρόπο, τα συστήματα συστάσεων έχουν τη δυνατότητα να εντοπίζουν βαθύτερες και λιγότερο εμφανείς συσχετίσεις, να αξιοποιούν έμμεσες συνδέσεις και να

παράγουν προτάσεις με μεγαλύτερη ακρίβεια και υψηλότερο βαθμό εξατομίκευσης. Παράλληλα, οι Karthik και Ganapathy (2021) αναφέρουν ότι οι σύγχρονες προσεγγίσεις αξιοποιούν και άλλες τεχνικές, όπως την ανάλυση συναισθήματος (sentiment analysis), την ασαφή λογική (fuzzy logic) και τις οντολογίες γνώσης. Οι τεχνικές αυτές συμβάλλουν στην πιο ρεαλιστική αποτύπωση της πολυπλοκότητας των ανθρώπινων προτιμήσεων, οι οποίες συχνά δεν μπορούν να περιγράφουνε πλήρως μόνο μέσα από απλές αξιολογήσεις ή ιστορικά δεδομένα.

Συνοψίζοντας, τα συστήματα συστάσεων αποτελούν έναν βασικό μηχανισμό υποστήριξης αποφάσεων στο σύγχρονο ψηφιακό περιβάλλον. Συνδυάζουν δεδομένα, αλγοριθμικές μεθόδους και τεχνητή νοημοσύνη, με σκοπό την παροχή εξατομικευμένων προτάσεων που ανταποκρίνονται καλύτερα στις ανάγκες και τις προτιμήσεις των χρηστών. Η λειτουργία τους βασίζεται σε έναν συνεχή κύκλο συλλογής δεδομένων, ανάλυσης, πρόβλεψης και βελτίωσης, γεγονός που τους επιτρέπει να προσαρμόζονται δυναμικά στη μεταβαλλόμενη συμπεριφορά των χρηστών.

2.2. Κατηγορίες Συστημάτων Συστάσεων

Τα συστήματα συστάσεων μπορούν να ταξινομηθούν σε διαφορετικές κατηγορίες, ανάλογα με τη μεθοδολογία που χρησιμοποιούν για την παραγωγή των προτάσεων. Σύμφωνα με τους Ricci et al. (2010) και τους Adomavicius και Tuzhilin (2005), οι βασικές προσεγγίσεις είναι τρεις: το συνεργατικό φιλτράρισμα (collaborative filtering), το φιλτράρισμα βάσει περιεχομένου (content-based filtering) και τα υβριδικά μοντέλα, τα οποία συνδυάζουν στοιχεία από τις δύο προηγούμενες προσεγγίσεις.

Η συγκεκριμένη τριμερής διάκριση αποτελεί ένα από τα βασικά σημεία αναφοράς στη σχετική βιβλιογραφία και χρησιμοποιείται ευρέως τόσο σε θεωρητικές αναλύσεις όσο και σε πρακτικές εφαρμογές συστημάτων συστάσεων (Papadakis et al., 2022). Κάθε κατηγορία παρουσιάζει διαφορετικά πλεονεκτήματα, περιορισμούς και απαιτήσεις ως προς τα δεδομένα που χρειάζεται για να λειτουργήσει αποτελεσματικά. Για τον λόγο αυτό, η επιλογή της κατάλληλης προσέγγισης εξαρτάται σε μεγάλο βαθμό από το είδος της εφαρμογής, το διαθέσιμο σύνολο δεδομένων και τους στόχους της επιχείρησης ή της πλατφόρμας στην οποία εφαρμόζεται.

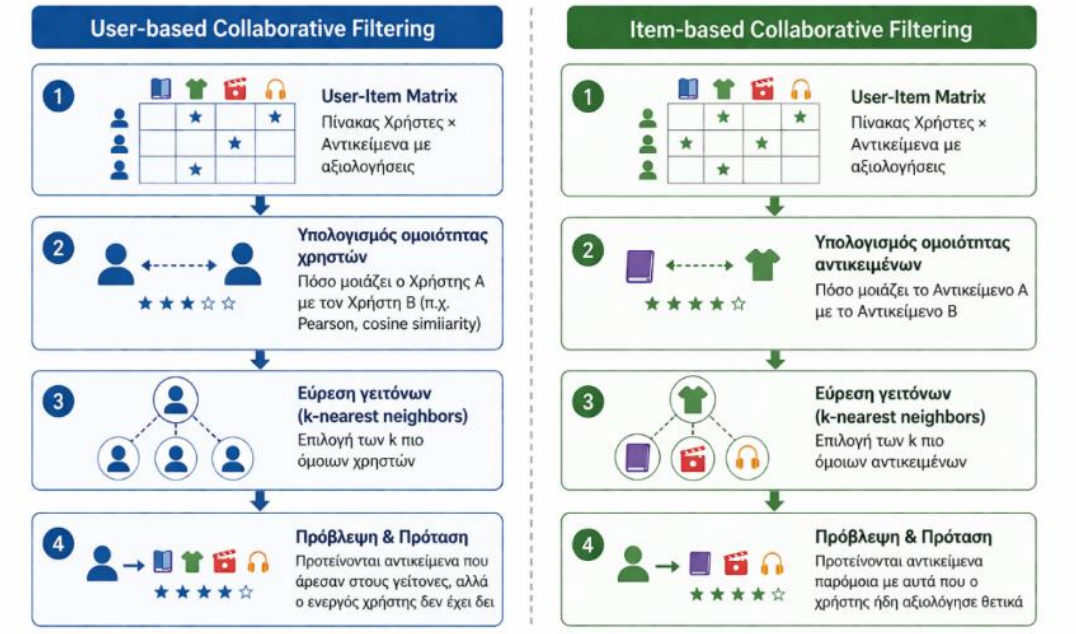
2.2.1. Συνεργατικό Φιλτράρισμα (Collaborative Filtering)

Το συνεργατικό φιλτράρισμα αποτελεί μία από τις πιο διαδεδομένες τεχνικές στα συστήματα συστάσεων. Η λειτουργία του βασίζεται στη συλλογική συμπεριφορά των χρηστών και στην υπόθεση ότι χρήστες που παρουσίασαν παρόμοια πρότυπα προτιμήσεων στο παρελθόν είναι πιθανό να εκδηλώσουν παρόμοιες προτιμήσεις και στο μέλλον (Adomavicius & Tuzhilin, 2005). Ένα βασικό χαρακτηριστικό της μεθόδου είναι ότι δεν απαιτεί αναλυτική γνώση των χαρακτηριστικών των αντικειμένων. Αντίθετα, αξιοποιεί κυρίως δεδομένα αλληλεπίδρασης, όπως αξιολογήσεις, αγορές, clicks ή ιστορικό πλοήγησης. Η λογική του μπορεί να αποδοθεί με μια απλή ροή τριών βημάτων: πρώτον, ο χρήστης εκφράζει τις προτιμήσεις του μέσω αξιολογήσεων ή συμπεριφοράς· δεύτερον, το σύστημα συγκρίνει αυτές τις προτιμήσεις με εκείνες άλλων χρηστών για να εντοπίσει άτομα με παρόμοια «γούστα»· και τρίτον, προτείνει αντικείμενα που άρεσαν σε εκείνους αλλά δεν έχει ανακαλύψει ακόμα ο τρέχων χρήστης (Adomavicius & Tuzhilin, 2005· Schafer, Konstan & Riedl, 2001).

Σύμφωνα με την ταξινόμηση των Papadakis et al. (2022), το collaborative filtering διακρίνεται σε δύο βασικές κατηγορίες: τις προσεγγίσεις που βασίζονται στη μνήμη (memory-based) και τις προσεγγίσεις που βασίζονται σε μοντέλα (model-based). Οι πρώτες στηρίζονται κυρίως στην άμεση σύγκριση χρηστών ή αντικειμένων, ενώ οι δεύτερες αξιοποιούν τεχνικές μηχανικής μάθησης για την πρόβλεψη των προτιμήσεων.

Όσον αφορά την προσέγγιση, User-Based Collaborative Filtering, το σύστημα αναζητά χρήστες με παρόμοια συμπεριφορά και, στη συνέχεια, προτείνει στον χρήστη αντικείμενα που έχουν αξιολογηθεί θετικά από αυτούς. Η ομοιότητα μεταξύ των χρηστών υπολογίζεται συνήθως με μετρικές ομοιότητας, όπως η συσχέτιση Pearson, ή η cosine similarity, οι οποίες επιτρέπουν την εκτίμηση του βαθμού εγγύτητας των προτιμήσεών τους (Alamdari et al., 2020). Αξίζει να αναφέρουμε πως ο συντελεστής συσχέτισης Pearson μετρά τη γραμμική συσχέτιση μεταξύ δύο συνόλων δεδομένων, λαμβάνοντας τιμές από –1 (τέλεια αρνητική συσχέτιση) έως +1 (τέλεια θετική συσχέτιση). Στα συνεργατικά φίλτρα, χρησιμοποιείται για να εκτιμηθεί πόσο παρόμοιες είναι οι αξιολογήσεις δύο χρηστών, λαμβάνοντας υπόψη τη διακύμανση και τον μέσο όρο των βαθμολογιών τους (Field, 2013). Από την άλλη, η ομοιότητα συνημιτόνου (cosine similarity) μετρά το συνημίτονο της γωνίας μεταξύ δύο διανυσμάτων, οπότε οι χρήστες αναπαρίστανται ως διανύσματα των αξιολογήσεών τους. Τιμές κοντά στο 1 υποδηλώνουν πολύ όμοιες προτιμήσεις, στο 0 ασύνδετες, και στο –1 αντίθετες (Manning, Raghavan & Schütze, 2008).

Έπειτα, η item-based προσέγγιση εστιάζει στην ομοιότητα μεταξύ των αντικειμένων. Σε αυτή την περίπτωση, το σύστημα προτείνει αντικείμενα που παρουσιάζουν παρόμοια πρότυπα αξιολόγησης ή χρήσης από τους χρήστες. Όπως επισημαίνουν οι Sarwar et al. (2001) και οι Alamdari et al. (2020), η συγκεκριμένη μέθοδος θεωρείται συχνά πιο αποδοτική για συστήματα μεγάλης κλίμακας, καθώς προσφέρει καλύτερη επεκτασιμότητα και μπορεί να ανταποκριθεί αποτελεσματικότερα σε περιβάλλοντα με μεγάλο αριθμό χρηστών και αντικειμένων. Η σύγκριση μεταξύ των δύο αυτών προσεγγίσεων παρουσιάζεται παρακάτω στο Σχεδιάγραμμα 2.3. Παρά την ευρεία εφαρμογή του, το collaborative filtering αντιμετωπίζει ορισμένες σημαντικές προκλήσεις. Οι κυριότερες είναι το πρόβλημα της ψυχρής εκκίνησης (cold start), όπου η απουσία πολλών δεδομένων οδηγεί σε μη βέλτιστες προτάσεις, η αραιότητα των δεδομένων (data sparsity) και η τάση προς την προώθηση δημοφιλών αντικειμένων (popularity bias). Οι παράγοντες αυτοί μπορούν να περιορίσουν την ακρίβεια και την ποικιλία των συστάσεων, επηρεάζοντας τελικά την αποτελεσματικότητα του συστήματος (Papadakis et al., 2022).



Σχεδιάγραμμα 2. 3

Σύγκριση των δύο βασικών προσεγγίσεων συνεργατικού φιλτραρίσματος. Στην User-based μέθοδο (αριστερά), η ομοιότητα υπολογίζεται μεταξύ χρηστών. Στην Item-based μέθοδο (δεξιά), η ομοιότητα υπολογίζεται μεταξύ αντικειμένων. *Προσαρμογή από Alamdari et al. (2020) και Papadakis et al. (2022).*

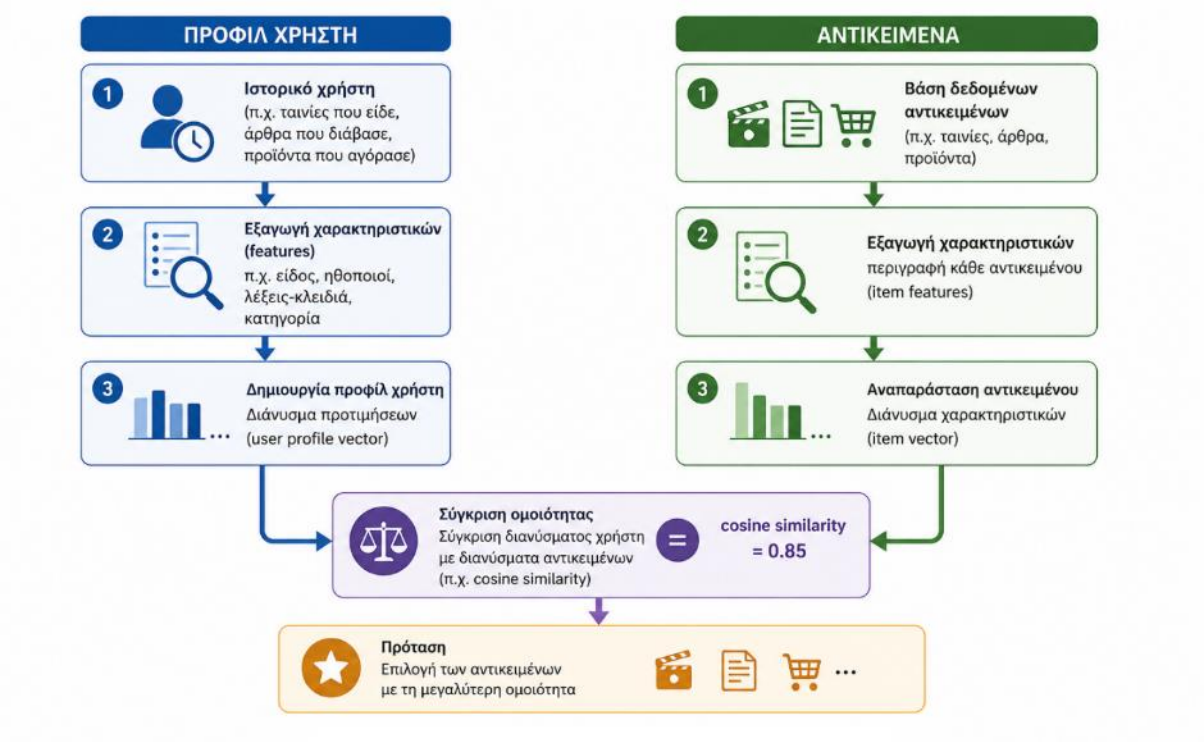
2.2.2. Φιλτράρισμα Βάσει Περιεχομένου (Content-Based Filtering)

Το φιλτράρισμα βάσει περιεχομένου αποτελεί μια διαφορετική προσέγγιση στα συστήματα συστάσεων, η οποία στηρίζεται κυρίως στα χαρακτηριστικά των αντικειμένων και στις ατομικές προτιμήσεις του κάθε χρήστη. Σε αντίθεση με το collaborative filtering, η μέθοδος αυτή δεν χρειάζεται δεδομένα από άλλους χρήστες, αλλά βασίζεται αποκλειστικά στο ιστορικό και στη συμπεριφορά του συγκεκριμένου χρήστη (Lops et al., 2011). Η βασική της λογική είναι ότι ένας χρήστης είναι πιθανό να προτιμήσει αντικείμενα που παρουσιάζουν κοινά χαρακτηριστικά με εκείνα που έχει ήδη επιλέξει ή αξιολογήσει θετικά στο παρελθόν. Για τον σκοπό αυτό, κάθε αντικείμενο περιγράφεται μέσα από ένα σύνολο χαρακτηριστικών (features), ενώ το προφίλ του χρήστη διαμορφώνεται με βάση τις προηγούμενες προτιμήσεις και αλληλεπιδράσεις του (Ricci et al., 2010). Η γενική λογική του content-based filtering παρουσιάζεται στο Σχεδιάγραμμα 2.4. Η σύγκριση ανάμεσα στο προφίλ του χρήστη και στα χαρακτηριστικά των αντικειμένων πραγματοποιείται συνήθως με τη χρήση μετρικών ομοιότητας, όπως η cosine similarity που είδαμε παραπάνω. Σε περιπτώσεις όπου τα δεδομένα έχουν μορφή κειμένου, αξιοποιούνται συχνά τεχνικές επεξεργασίας φυσικής γλώσσας (Natural Language Processing - NLP), ώστε να αναλυθεί και να αξιοποιηθεί αποτελεσματικότερα το περιεχόμενο (Pazzani & Billsus, 2007).

Το content-based filtering παρουσιάζει ορισμένα σημαντικά πλεονεκτήματα. Μπορεί να προσφέρει προτάσεις ιδιαίτερα εξατομικευμένες και, σε αρκετές περιπτώσεις, πιο εύκολα ερμηνεύσιμες, καθώς βασίζονται σε συγκεκριμένα χαρακτηριστικά των αντικειμένων. Επιπλέον, μπορεί να συμβάλει στην αντιμετώπιση του προβλήματος της ψυχρής εκκίνησης για νέους χρήστες, υπό την προϋπόθεση ότι υπάρχει κάποιο αρχικό προφίλ ή βασική πληροφορία για τις προτιμήσεις τους. Ωστόσο, η μέθοδος παρουσιάζει και περιορισμούς. Η αποτελεσματικότητά της εξαρτάται σε μεγάλο βαθμό από τη διαθεσιμότητα, την ακρίβεια και την ποιότητα των χαρακτηριστικών των αντικειμένων. Παράλληλα, μπορεί να οδηγήσει σε υπερβολικά εξειδικευμένες προτάσεις (over-specialization), περιορίζοντας την ποικιλία των επιλογών που παρουσιάζονται στον χρήστη (Lops et al., 2011).

Σύγχρονες εξελίξεις στον τομέα επιχειρούν να περιορίσουν αυτούς τους περιορισμούς και να ενισχύσουν την ακρίβεια των προτάσεων. Όπως αναφέρουν οι Karthik και Ganapathy (2021), νεότερες προσεγγίσεις ενσωματώνουν τεχνικές όπως η ανάλυση συναισθήματος (sentiment

analysis) και η ασαφής λογική (fuzzy logic). Οι τεχνικές αυτές επιτρέπουν την πιο ολοκληρωμένη αποτύπωση των προτιμήσεων των χρηστών, ιδιαίτερα σε περιβάλλοντα ηλεκτρονικού εμπορίου, όπου οι επιλογές επηρεάζονται συχνά από πιο σύνθετους και υποκειμενικούς παράγοντες.



Σχεδιάγραμμα 2. 4

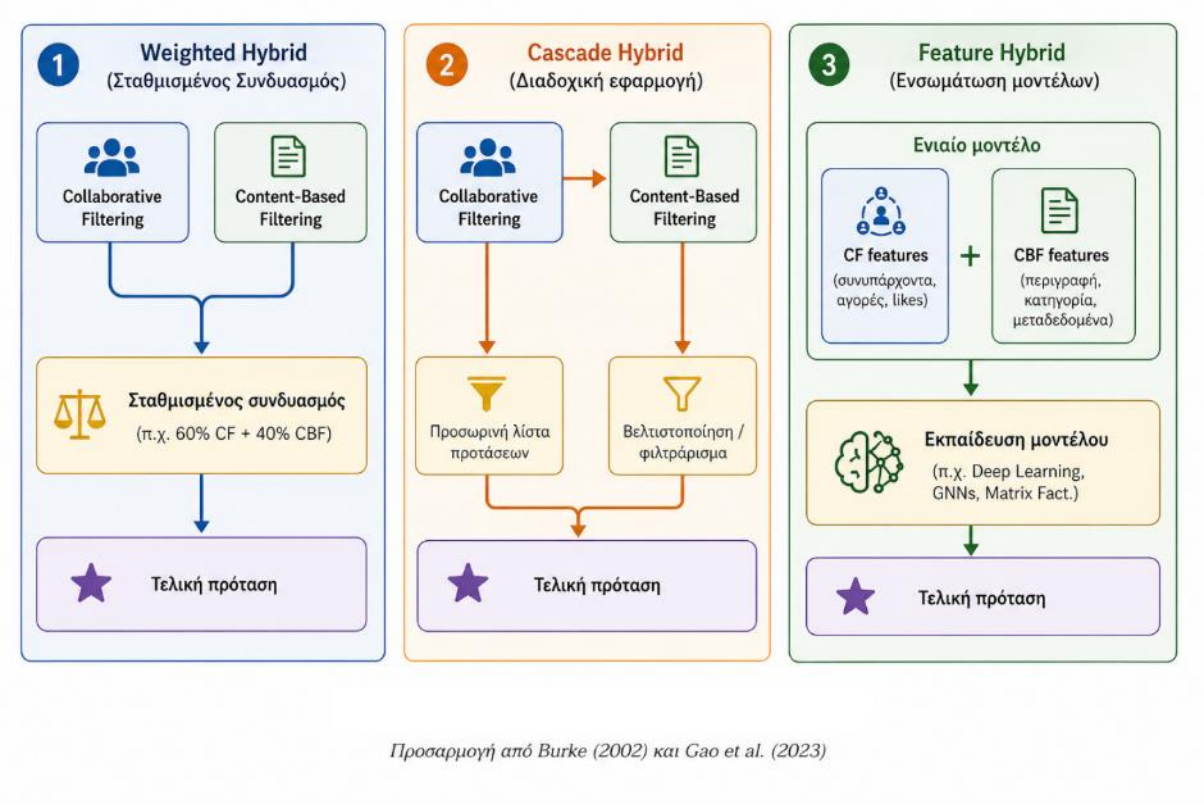
Η λογική του φιλτραρίσματος βάσει περιεχομένου. Το σύστημα δημιουργεί ένα προφίλ χρήστη από το ιστορικό αλληλεπιδράσεων (αριστερά) και συγκρίνει το προφίλ αυτό με τα χαρακτηριστικά των διαθέσιμων αντικειμένων (δεξιά). Τα αντικείμενα με τη μεγαλύτερη ομοιότητα προτείνονται στον χρήστη. *Προσαρμογή από Lops et al. (2011) και Pazzani & Billsus (2007).*

2.2.3. Υβριδικά Μοντέλα (Hybrid Recommender Systems)

Τα υβριδικά συστήματα συστάσεων συνδυάζουν περισσότερες από μία τεχνικές, με συνηθέστερο τον συνδυασμό του collaborative filtering και του content-based filtering.

Στόχος τους είναι να αξιοποιήσουν τα πλεονεκτήματα κάθε μεθόδου και, παράλληλα, να περιορίσουν τις αδυναμίες που μπορεί να εμφανίζει καθεμία όταν εφαρμόζεται μεμονωμένα. Όπως σημειώνει ο Burke (2002), η ανάγκη για υβριδικές προσεγγίσεις προκύπτει κυρίως σε

περιπτώσεις όπου μία μόνο τεχνική δεν επαρκεί για την παραγωγή ακριβών, αξιόπιστων ή αρκετά διαφοροποιημένων προτάσεων. Για τον λόγο αυτό, τα υβριδικά μοντέλα θεωρούνται ιδιαίτερα σημαντικά σε πιο σύνθετα περιβάλλοντα εφαρμογής, όπου τα δεδομένα των χρηστών και των αντικειμένων παρουσιάζουν ποικιλία και διαφορετικά επίπεδα πληρότητας. Οι βασικοί τρόποι υλοποίησης των υβριδικών συστημάτων περιλαμβάνουν τον σταθμισμένο συνδυασμό αποτελεσμάτων (weighted hybrid), τη διαδοχική εφαρμογή μεθόδων (cascade) και την ενσωμάτωση πολλαπλών μοντέλων σε ένα ενιαίο σύστημα. Οι τρεις αυτές προσεγγίσεις παρουσιάζονται στο Σχεδιάγραμμα 2.5.



Σχεδιάγραμμα 2. 5

Υβριδικά συστήματα συστάσεων: τρεις βασικοί τρόποι συνδυασμού συνεργατικού φιλτραρίσματος (CF) και φιλτραρίσματος βάσει περιεχομένου (CBF). (α) Weighted hybrid: σταθμισμένος συνδυασμός αποτελεσμάτων, (β) Cascade hybrid: διαδοχική εφαρμογή μεθόδων, (γ) Feature hybrid: ενσωμάτωση χαρακτηριστικών από πολλαπλές πηγές σε ενιαίο μοντέλο. *Προσαρμογή από Burke (2002) και Gao et al. (2023).*

Ακόμα, η πρόοδος της τεχνητής νοημοσύνης έχει συμβάλει σημαντικά στην εξέλιξη και ενίσχυση των υβριδικών μοντέλων συστάσεων. Σύμφωνα με τους Gao et al. (2023), τεχνικές όπως η βαθιά μάθηση (deep learning) και τα Graph Neural Networks (GNNs) δίνουν τη

δυνατότητα στα συστήματα να αξιοποιούν πιο σύνθετες σχέσεις μεταξύ χρηστών και αντικειμένων. Με τον τρόπο αυτό, οι συστάσεις δεν βασίζονται μόνο σε απλές ομοιότητες ή προηγούμενες αλληλεπιδράσεις, αλλά μπορούν να ενσωματώνουν βαθύτερα πρότυπα συμπεριφοράς και συσχετίσεις.

Σήμερα, τα υβριδικά συστήματα θεωρούνται από τις πιο αποτελεσματικές προσεγγίσεις στον χώρο των recommender systems. Αυτό οφείλεται στο γεγονός ότι μπορούν να επιτύχουν υψηλότερη ακρίβεια, καλύτερη προσαρμοστικότητα και μεγαλύτερη ποικιλία στις προτάσεις που παράγουν. Για τους λόγους αυτούς, θεωρούνται ιδιαίτερα κατάλληλα για σύγχρονες εφαρμογές μεγάλης κλίμακας, όπου οι ανάγκες των χρηστών είναι διαφορετικές και τα διαθέσιμα δεδομένα ιδιαίτερα εκτεταμένα (Alamdari et al., 2020).

Μια συνοπτική σύγκριση των τριών βασικών κατηγοριών παρουσιάζεται στον Πίνακα 2.1, όπου συνοψίζονται τα κύρια χαρακτηριστικά, τα πλεονεκτήματα και οι περιορισμοί κάθε προσέγγισης.

Κριτήριο	**Συνεργατικό Φιλτράρισμα (CF)**	**Φιλτράρισμα Βάσει Περ/μένου (CBF)**	**Υβριδικά Συστήματα**
Βασική αρχή	Χρήστες με παρόμοια συμπεριφορά έχουν παρόμοιες προτιμήσεις	Ο χρήστης προτιμά αντικείμενα με παρόμοια χαρακτηριστικά	Συνδυασμός CF και CBF
Τύπος δεδομένων	Δεδομένα αλληλεπίδρασης χρηστών (ratings, clicks)	Χαρακτηριστικά αντικειμένων και προφίλ χρήστη	Συνδυασμός πολλαπλών τύπων δεδομένων
Ανάγκη για άλλους χρήστες	Ναι	Όχι	Ναι/Όχι (ανάλογα την υλοποίηση)
Cold Start	Πρόβλημα σε νέους χρήστες/αντικείμενα	Καλύτερη αντιμετώπιση για χρήστες	Σημαντικά μειωμένο

Data Sparsity	Υψηλή επίδραση	Χαμηλότερη επίδραση	Αντιμετωπίζεται
Επεκτασιμότητα	Περιορισμένη σε μεγάλα datasets	Καλή	Πολύ καλή
Ποικιλία προτάσεων	Μέτρια	Χαμηλή (over-specialization)	Υψηλή
Ερμηνευσιμότητα	Περιορισμένη	Υψηλή	Μέτρια
Ακρίβεια	Υψηλή (όταν υπάρχουν δεδομένα)	Μέτρια	Πολύ υψηλή
Χρήση στην πράξη	Amazon (item-based), Netflix (παλαιότερα CF)	News, content platforms	Netflix, Spotify, e-commerce

Πίνακας 2. 1 : Σύγκριση κατηγοριών συστημάτων συστάσεων

Πηγή: Προσαρμογή από Ricci et al. (2010); Lops et al. (2011); Papadakis et al. (2022); Alamdari et al. (2020)

2.3. Μέτρα Απόδοσης και Αξιολόγησης

Η αξιολόγηση των συστημάτων συστάσεων αποτελεί βασικό στάδιο για τη διασφάλιση της ποιότητας και της αποτελεσματικότητας των προτάσεων που παράγουν. Εφόσον τα RS στηρίζονται στην πρόβλεψη των προτιμήσεων των χρηστών, η αποτίμηση της απόδοσής τους απαιτεί τη χρήση κατάλληλων μετρικών. Οι μετρικές αυτές επιτρέπουν τη σύγκριση διαφορετικών αλγορίθμων, αλλά και την επιλογή της καταλληλότερης προσέγγισης ανάλογα με το είδος και τις ανάγκες κάθε εφαρμογής (Ricci et al., 2010, Jannach & Jugovac, 2019). Πέρα από τις τεχνικές μετρικές, η αξιολόγηση των RS οφείλει να λαμβάνει υπόψη και επιχειρηματικούς δείκτες που συνδέουν άμεσα την απόδοση των αλγορίθμων με την επιχειρησιακή αξία. Τέτοιοι δείκτες περιλαμβάνουν το ποσοστό μετατροπής (Conversion Rate), τη μέση αξία παραγγελίας (Average Order Value – AOV), το ποσοστό κλικ (Click-Through Rate – CTR), την αξία διάρκειας ζωής πελάτη (Customer Lifetime Value – CLV) και την απόδοση επένδυσης (Return on Investment – ROI) (Jannach & Jugovac, 2019). Η ανάλυση στο παρόν εστιάζει στις τεχνικές μετρικές, ενώ οι επιχειρηματικές συζητιούνται στα Κεφ. 3 και 5.

Ωστόσο, είναι σημαντικό να τονιστεί ότι η σχέση ανάμεσα στις αλγοριθμικές και τις επιχειρηματικές μετρικές δεν είναι πάντοτε ευθύγραμμη. Μια βελτίωση, για παράδειγμα, στο

MAE ή το RMSE δεν συνεπάγεται αυτόματα υψηλότερο conversion rate ή μεγαλύτερο μέσο καλάθι αγορών. Οι αλγοριθμικές μετρικές αποτυπώνουν την ικανότητα του μοντέλου να προβλέπει σωστά, αλλά η επιχειρηματική επιτυχία εξαρτάται και από άλλους παράγοντες, όπως ο σχεδιασμός της διεπαφής, η εμπιστοσύνη του χρήστη και το πλαίσιο χρήσης. Για τον λόγο αυτό, η αξιολόγηση ενός recommender system οφείλει να είναι πολυδιάστατη, συνδυάζοντας τεχνικές και επιχειρηματικές μετρικές για μια ολοκληρωμένη εικόνα της απόδοσής του.

Σύμφωνα με τους Papadakis et al. (2022), οι μετρικές αξιολόγησης των συστημάτων συστάσεων μπορούν να διακριθούν σε δύο βασικές κατηγορίες: στις μετρικές ακρίβειας πρόβλεψης και στις μετρικές αξιολόγησης της κατάταξης.

2.3.1. Μετρικές κατάταξης: Precision, Recall και F1

Στην κατηγορία των μετρικών κατάταξης περιλαμβάνονται οι δείκτες precision (ακρίβεια) και recall (ανάκληση). Όπως ορίζουν οι Herlocker et al. (2004), το precision εκφράζει το ποσοστό των αντικειμένων που προτάθηκαν από το σύστημα και είναι πράγματι σχετικά με τις ανάγκες ή τα ενδιαφέροντα του χρήστη. Αντίστοιχα, το recall εκφράζει το ποσοστό των σχετικών αντικειμένων που κατάφερε να εντοπίσει και να προτείνει το σύστημα.

Οι δύο αυτές μετρικές λειτουργούν συμπληρωματικά. Το precision εστιάζει κυρίως στην ακρίβεια των προτάσεων, δηλαδή στο κατά πόσο οι προτάσεις που εμφανίζονται στον χρήστη είναι πράγματι χρήσιμες ή σχετικές. Από την άλλη πλευρά, το recall δίνει μεγαλύτερη έμφαση στην πληρότητα, εξετάζοντας κατά πόσο το σύστημα κατάφερε να εντοπίσει το σύνολο ή ένα σημαντικό μέρος των σχετικών επιλογών.

Ωστόσο, η ταυτόχρονη βελτιστοποίηση και των δύο μετρικών δεν είναι πάντοτε εύκολη, καθώς συχνά η αύξηση της μίας μπορεί να επηρεάσει την άλλη. Για τον λόγο αυτό, χρησιμοποιείται συχνά ο δείκτης F1, ο οποίος εκφράζει τον αρμονικό μέσο της precision και της recall και προσφέρει μια πιο ισορροπημένη εικόνα της απόδοσης του συστήματος (Herlocker et al., 2004). Οι ορισμοί και οι τύποι των τριών αυτών μετρικών παρουσιάζονται συνοπτικά στον Πίνακα 2.2 παρακάτω.

Μετρική	Τι μετράει	Τύπος
Precision (Ακρίβεια)	Ποσοστό των προτεινόμενων αντικειμένων που είναι πράγματι σχετικά	$\text{Precision} = \frac{\text{Σχετικά προτεινόμενα}}{\text{Σύνολο προτεινόμενων}} = \frac{TP}{TP + FP}$

Recall (Ανάκληση)	Ποσοστό των συνολικά σχετικών αντικειμένων που προτάθηκαν	$\text{Recall} = \frac{\text{Σχετικά προτεινόμενα}}{\text{Σύνολο σχετικών}} = \frac{TP}{TP + FN}$
F1-Score	Αρμονικός μέσος Precision και Recall (ισορροπία)	$F1 = 2 \times \frac{\text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}}$

Πίνακας 2. 2 Βασικές μετρικές αξιολόγησης συστημάτων συστάσεων

Η Precision μετρά την ακρίβεια των προτάσεων, η Recall την πληρότητα, και το F1-Score αποτελεί τον αρμονικό μέσο των δύο. *Προσαρμογή από Herlocker et al. (2004).*

Επεξήγηση συμβόλων:

- TP (True Positive): Σχετικό αντικείμενο που προτάθηκε
- FP (False Positive): Μη σχετικό αντικείμενο που προτάθηκε
- FN (False Negative): Σχετικό αντικείμενο που ΔΕΝ προτάθηκε
-

2.3.2. Μετρικές σφάλματος πρόβλεψης: MAE και RMSE

Για την αξιολόγηση της ακρίβειας των προβλέψεων, ιδιαίτερα σε περιβάλλοντα όπου το σύστημα εκτιμά αριθμητικές τιμές, όπως βαθμολογίες ή επίπεδα προτίμησης, χρησιμοποιούνται συχνά μετρικές όπως το Mean Absolute Error (MAE) και το Root Mean Square Error (RMSE). Το MAE υπολογίζει τον μέσο όρο των απόλυτων διαφορών ανάμεσα στις πραγματικές (y_i) και τις προβλεπόμενες ($\hat{y}_i$) τιμές, δίνοντας μια άμεση εικόνα του μέσου σφάλματος:

$$\text{MAE} = \frac{1}{n}\sum_{i=1}^{n} | y_i - \hat{y}_i |$$

Το RMSE υπολογίζει την τετραγωνική ρίζα του μέσου των τετραγωνικών διαφορών:

$$\text{RMSE} = \sqrt{\frac{1}{n}\sum_{i=1}^{n} (y_i - \hat{y}_i)^2}$$

Όπου:

- n είναι το πλήθος των προβλέψεων,

- y_i η πραγματική αξιολόγηση του χρήστη,
- $\hat{y}_i$ η προβλεπόμενη αξιολόγηση από το σύστημα.

Λόγω του τετραγωνισμού των σφαλμάτων, το RMSE δίνει δυσανάλογα μεγαλύτερη βαρύτητα στις μεγάλες αποκλίσεις, γεγονός που το καθιστά καταλληλότερο όταν τα μεγάλα σφάλματα είναι ιδιαίτερα ανεπιθύμητα (Alamdari et al., 2020).

Όπως εξηγούν οι Alamdari et al. (2020), το MAE μετρά τη μέση απόλυτη απόκλιση ανάμεσα στις πραγματικές και στις προβλεπόμενες τιμές, προσφέροντας μια άμεση και εύκολα κατανοητή ένδειξη του μέσου σφάλματος του συστήματος. Αντίστοιχα, το RMSE υπολογίζει τη ρίζα του μέσου τετραγωνικού σφάλματος και δίνει μεγαλύτερη βαρύτητα στις μεγάλες αποκλίσεις. Για τον λόγο αυτό, θεωρείται πιο αυστηρή μετρική, καθώς «τιμωρεί» περισσότερο τις προβλέψεις που απέχουν σημαντικά από τις πραγματικές τιμές. Η επιλογή ανάμεσα στο MAE και στο RMSE εξαρτάται από τη φύση της εφαρμογής και από το κατά πόσο είναι κρίσιμο για το σύστημα να αποφεύγει μεγάλες αποκλίσεις στις προβλέψεις του.

Επιπροσθέτως, η σύγχρονη βιβλιογραφία αναγνωρίζει ότι η αξιολόγηση των συστημάτων συστάσεων δεν μπορεί να περιορίζεται αποκλειστικά σε μετρικές ακρίβειας. Όπως επισημαίνουν οι Gao et al. (2023) και οι Jannach και Jugovac (2019), έχουν εισαχθεί και άλλες συμπληρωματικές διαστάσεις, οι οποίες αποτυπώνουν καλύτερα την ποιότητα της εμπειρίας του χρήστη. Ειδικότερα, εξετάζονται η ποικιλία (diversity), η καινοτομία (novelty), απροσδόκητη χρησιμότητα (serendipity) και η κάλυψη (coverage). Όσον αφορά την ποικιλία, αναφέρεται στην ικανότητα του συστήματος να προτείνει αντικείμενα που διαφέρουν μεταξύ τους, αποφεύγοντας την επανάληψη παρόμοιων επιλογών. Έπειτα, η καινοτομία εκφράζει τον βαθμό στον οποίο οι προτάσεις περιλαμβάνουν αντικείμενα που ο χρήστης δεν γνώριζε ήδη. Στην συνέχεια, η απροσδόκητη χρησιμότητα, αφορά την ικανότητα του συστήματος να προτείνει αντικείμενα που, αν και δεν είναι αναμενόμενα, αποδεικνύονται χρήσιμα ή ενδιαφέροντα για τον χρήστη. Τέλος, η κάλυψη (coverage) αναφέρεται στο ποσοστό των αντικειμένων του συστήματος που μπορούν πράγματι να εμφανιστούν ως προτάσεις.

Οι μετρικές αυτές δίνουν έμφαση όχι μόνο στο κατά πόσο οι προτάσεις είναι ακριβείς, αλλά και στο κατά πόσο είναι ενδιαφέρουσες, διαφοροποιημένες και ουσιαστικά χρήσιμες για τον χρήστη. Με αυτόν τον τρόπο, η αξιολόγηση μετατοπίζεται από μια στενά τεχνική προσέγγιση σε μια πιο ολοκληρωμένη θεώρηση της εμπειρίας που προσφέρει το σύστημα.

Σε σενάρια όπου η σειρά κατάταξης των προτάσεων έχει μεγαλύτερη σημασία από την απόλυτη αριθμητική πρόβλεψη, χρησιμοποιούνται επίσης μετρικές όπως το NDCG

(Normalized Discounted Cumulative Gain), το MAP (Mean Average Precision) και το MRR (Mean Reciprocal Rank), οι οποίες αξιολογούν την ποιότητα της ταξινόμησης (Herlocker et al., 2004).

Συμπερασματικά, η αξιολόγηση των recommender systems αποτελεί μια πολυδιάστατη διαδικασία, η οποία απαιτεί τον συνδυασμό διαφορετικών μετρικών, ανάλογα με τους στόχους του συστήματος και το επιχειρησιακό περιβάλλον στο οποίο εφαρμόζεται. Η αποκλειστική έμφαση στην ακρίβεια δεν επαρκεί, καθώς παράγοντες όπως η ποικιλία, η καινοτομία, η απροσδόκητη χρησιμότητα και η συνολική χρηστικότητα των προτάσεων διαδραματίζουν εξίσου σημαντικό ρόλο. Επομένως, η επιλογή και ο κατάλληλος συνδυασμός των μετρικών αξιολόγησης αποτελούν κρίσιμο παράγοντα για τη βελτιστοποίηση της λειτουργίας και της αποτελεσματικότητας των συστημάτων συστάσεων.

2.3.3. Επιχειρηματικές μετρικές απόδοσης

Πέρα από τις τεχνικές μετρικές, η αξιολόγηση των συστημάτων συστάσεων σε επιχειρησιακό επίπεδο απαιτεί τη χρήση δεικτών που συνδέουν άμεσα την αλγοριθμική απόδοση με τα οικονομικά αποτελέσματα (Jannach & Jugovac, 2019). Οι μετρικές αυτές είναι ιδιαίτερα χρήσιμες για τη λήψη στρατηγικών αποφάσεων, όπως η βελτιστοποίηση της διάταξης των προτάσεων ή η αξιολόγηση διαφορετικών αλγορίθμων μέσω A/B testing. Οι συνηθέστερες επιχειρηματικές μετρικές περιλαμβάνουν:

- **Ποσοστό μετατροπής (Conversion Rate):** Εκφράζει το ποσοστό των χρηστών που ολοκληρώνουν μια επιθυμητή ενέργεια (π.χ. αγορά, εγγραφή) αφού εκτεθούν σε μια πρόταση του συστήματος συστάσεων. Υπολογίζεται ως ο λόγος των μετατροπών που προέρχονται από RS προς το σύνολο των χρηστών που είδαν τις προτάσεις, επί εκατό.
- **Μέση Αξία Παραγγελίας (Average Order Value - AOV):** Μετρά το μέσο χρηματικό ποσό ανά συναλλαγή που προέρχεται από προτάσεις του RS. Προκύπτει από τη διαίρεση των συνολικών εσόδων που αποδίδονται στο σύστημα συστάσεων με τον αριθμό των αντίστοιχων συναλλαγών.
- **Ποσοστό Κλικ (Click-Through Rate - CTR):** Αποτελεί δείκτη της ελκυστικότητας των προτάσεων. Υπολογίζεται ως ο λόγος των κλικ που δέχονται οι προτεινόμενες επιλογές προς τον συνολικό αριθμό εμφανίσεών τους (impressions), επί εκατό.

- **Αξία Διάρκειας Ζωής Πελάτη (Customer Lifetime Value - CLV):** Εκτιμά τη συνολική κερδοφορία που αναμένεται από έναν πελάτη κατά τη διάρκεια ολόκληρης της σχέσης του με την πλατφόρμα. Η μετρική αυτή εξαρτάται από το μοντέλο πρόβλεψης που χρησιμοποιεί κάθε επιχείρηση, λαμβάνοντας υπόψη παράγοντες όπως το ιστορικό εσόδων, η συχνότητα αγορών και το ποσοστό διατήρησης (retention).
- **Απόδοση Επένδυσης (Return on Investment - ROI):** Αποτιμά την κερδοφορία της επένδυσης σε ένα σύστημα συστάσεων. Υπολογίζεται ως το πηλίκο του καθαρού κέρδους που αποδίδεται στο RS προς το συνολικό κόστος ανάπτυξης, εγκατάστασης και λειτουργίας του, επί εκατό.

Οι επιχειρηματικές αυτές μετρικές δεν υποκαθιστούν τις τεχνικές (π.χ. Precision, Recall), αλλά τις συμπληρώνουν, προσφέροντας μια πιο ολοκληρωμένη εικόνα της συμβολής των RS στη στρατηγική και στην κερδοφορία της επιχείρησης (Jannach & Jugovac, 2019). Για παράδειγμα, μια βελτίωση στο Precision δεν συνεπάγεται αυτόματα αύξηση του Conversion Rate, αν οι προτάσεις δεν εμφανίζονται στο κατάλληλο σημείο ή την κατάλληλη στιγμή. Για τον λόγο αυτό, οι επιχειρήσεις χρησιμοποιούν συχνά έναν συνδυασμό τεχνικών και επιχειρηματικών μετρικών κατά τη βελτιστοποίηση των RS.

2.4.Προκλήσεις και Περιορισμοί των Συστημάτων Συστάσεων

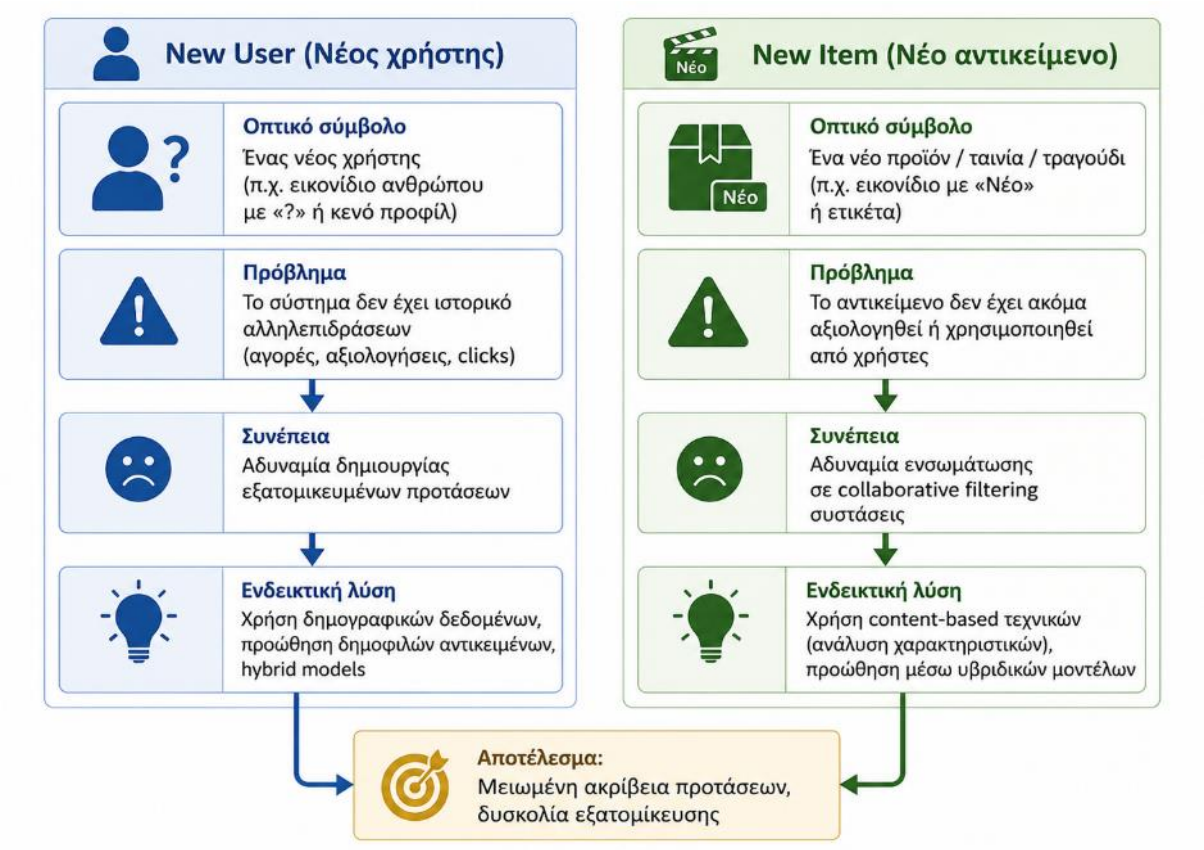
Παρά τη σημαντική πρόοδο που έχει σημειωθεί στον τομέα των συστημάτων συστάσεων και την ευρεία χρήση τους σε διαφορετικά ψηφιακά περιβάλλοντα, η ανάπτυξη και η λειτουργία τους εξακολουθούν να συνοδεύονται από ορισμένες σημαντικές προκλήσεις. Όπως επισημαίνουν οι Adomavicius και Tuzhilin (2005), καθώς και οι Ricci et al. (2010), οι περιορισμοί αυτοί μπορούν να επηρεάσουν άμεσα την ακρίβεια, την αξιοπιστία και τη συνολική χρηστικότητα των RS. Οι δυσκολίες αυτές σχετίζονται τόσο με τη φύση και την ποιότητα των διαθέσιμων δεδομένων όσο και με τις υπολογιστικές και μεθοδολογικές απαιτήσεις των αλγορίθμων που χρησιμοποιούνται.

2.4.1. Πρόβλημα ψυχρής εκκίνησης (Cold Start)

Ένα από τα πιο χαρακτηριστικά προβλήματα των συστημάτων συστάσεων είναι το πρόβλημα της ψυχρής εκκίνησης (cold start). Το πρόβλημα αυτό εμφανίζεται όταν το σύστημα δεν διαθέτει επαρκή δεδομένα για έναν νέο χρήστη ή για ένα νέο αντικείμενο. Σύμφωνα με τους

Papadakis et al. (2022) και τους Alamdari et al. (2020), στην περίπτωση των νέων χρηστών, η απουσία ιστορικού αλληλεπιδράσεων δυσκολεύει τη δημιουργία ενός αξιόπιστου προφίλ προτιμήσεων. Ως αποτέλεσμα, το σύστημα δεν μπορεί να προβλέψει με ακρίβεια ποια προϊόντα, υπηρεσίες ή περιεχόμενο είναι πιθανό να τους ενδιαφέρουν.

Αντίστοιχα, στην περίπτωση των νέων αντικειμένων, τα οποία δεν έχουν ακόμη αξιολογηθεί ή χρησιμοποιηθεί από επαρκή αριθμό χρηστών, το σύστημα δυσκολεύεται να τα ενσωματώσει αποτελεσματικά στη διαδικασία παραγωγής συστάσεων. Το πρόβλημα αυτό είναι ιδιαίτερα έντονο στα μοντέλα collaborative filtering, καθώς τα συγκεκριμένα μοντέλα βασίζονται σε μεγάλο βαθμό σε ιστορικά δεδομένα αλληλεπίδρασης. Για την αντιμετώπιση αυτού του προβλήματος, οι πλατφόρμες συχνά επιστρατεύουν πρακτικές όπως ερωτηματολόγια κατά την εγγραφή, αξιολόγηση ενός αρχικού σετ αντικειμένων, οπτική επιλογή ανάμεσα σε εικόνες ή τίτλους, χρήση ετικετών (tags) που περιγράφουν τα ενδιαφέροντα του χρήστη, καθώς και συστάσεις βασισμένες σε έμπειρους χρήστες (Papadakis et al., 2022· Gao et al., 2023). Οι δύο αυτές περιπτώσεις απεικονίζονται στο Σχεδιάγραμμα 2.6.



Σχεδιάγραμμα 2. 6

Το πρόβλημα της ψυχρής εκκίνησης (cold start) σε συστήματα συστάσεων. Αριστερά: νέος χρήστης χωρίς ιστορικό αλληλεπιδράσεων. Δεξιά: νέο αντικείμενο χωρίς αξιολογήσεις. Και οι δύο περιπτώσεις οδηγούν σε μειωμένη ακρίβεια προτάσεων. *Προσαρμογή από Papadakis et al. (2022) και Panda & Ray (2022).*

2.4.2. Αραιότητα δεδομένων (Data Sparsity)

Στενά συνδεδεμένο με το πρόβλημα της ψυχρής εκκίνησης είναι και το ζήτημα της αραιότητας των δεδομένων. Όπως εξηγούν οι Ricci et al. (2010) και οι Jannach και Jugovac (2019), το πρόβλημα αυτό εμφανίζεται όταν ο πίνακας αλληλεπιδράσεων μεταξύ χρηστών και αντικειμένων περιέχει μεγάλο αριθμό κενών τιμών. Στην πράξη, οι περισσότεροι χρήστες αλληλεπιδρούν μόνο με ένα μικρό μέρος των διαθέσιμων αντικειμένων, ενώ το μεγαλύτερο μέρος των πιθανών συνδυασμών χρήστη-αντικειμένου παραμένει χωρίς δεδομένα.

Η κατάσταση αυτή δυσκολεύει τον εντοπισμό αξιόπιστων συσχετίσεων και μειώνει την ακρίβεια των προβλέψεων. Η αραιότητα των δεδομένων αποτελεί ιδιαίτερα σημαντικό εμπόδιο σε εφαρμογές μεγάλης κλίμακας, όπου ο αριθμός των χρηστών και των αντικειμένων είναι πολύ μεγάλος και οι διαθέσιμες αλληλεπιδράσεις δεν επαρκούν πάντα για την παραγωγή αξιόπιστων συστάσεων.

2.4.3. Μεροληψία (Bias)

Ένας ακόμη σημαντικός περιορισμός των συστημάτων συστάσεων είναι η μεροληψία (bias), η οποία μπορεί να εμφανιστεί με διαφορετικές μορφές και να επηρεάσει αρνητικά τόσο την εμπειρία των χρηστών όσο και την αξιοπιστία των νέων προτάσεων. Σε αντίθεση με προβλήματα που σχετίζονται αποκλειστικά με την έλλειψη δεδομένων, όπως η ψυχρή εκκίνηση ή η αραιότητα, η μεροληψία συχνά προκύπτει από τον ίδιο τον τρόπο συλλογής και αξιοποίησης των δεδομένων, καθώς και από τις σχεδιαστικές επιλογές των αλγορίθμων (Adomavicius & Tuzhilin, 2005).

Μία από τις πιο συχνά παρατηρούμενες μορφές είναι η μεροληψία δημοτικότητας (popularity bias), δηλαδή η τάση του συστήματος να προτείνει κυρίως δημοφιλή αντικείμενα. Το φαινόμενο αυτό εμφανίζεται επειδή τα δημοφιλή αντικείμενα έχουν συνήθως περισσότερες αλληλεπιδράσεις και αξιολογήσεις, με αποτέλεσμα ο αλγόριθμος να τα θεωρεί ασφαλέστερες επιλογές. Ωστόσο, η πρακτική αυτή μπορεί να περιορίσει την ποικιλία των προτάσεων, να ενισχύσει περαιτέρω τη συγκέντρωση της ζήτησης γύρω από ήδη γνωστά προϊόντα ή

υπηρεσίες και να μειώσει την προβολή λιγότερο δημοφιλών αντικειμένων, ακόμη και αν αυτά είναι απολύτως σχετικά με τα ενδιαφέροντα του χρήστη (Fleder & Hosanagar, 2009, Jannach & Jugovac, 2019). Με αυτόν τον τρόπο δημιουργείται ένα φαινόμενο «ο πλούσιος γίνεται πλουσιότερος» (rich-get-richer effect), όπου η αρχική δημοτικότητα ενός αντικειμένου τροφοδοτεί έναν κύκλο θετικής ανατροφοδότησης που μειώνει την προβολή λιγότερο γνωστών αλλά δυνητικά σχετικών επιλογών (Fleder & Hosanagar, 2009). Με το πέρας του χρόνου, η ενίσχυση των ήδη δημοφιλών επιλογών μπορεί να οδηγήσει σε ένα φαινόμενο όπου συγκεκριμένα αντικείμενα προτείνονται συνέχεια, ενώ άλλα όχι με αποτέλεσμα να μην προβάλλονται και να μην επιλέγονται. Μια δεύτερη μορφή είναι η αλγοριθμική μεροληψία (algorithmic bias), η οποία σχετίζεται με τη δομή των δεδο-μένων, τις παραδοχές που ενσωματώνονται κατά τον σχεδιασμό του μοντέλου ή τον τρόπο εκπαίδευσης του αλγορίθμου. Για παράδειγμα, κατά την εκπαίδευση του RS γίνουν πολλές αλληλεπιδράσεις από μια συγκεκριμένη ομάδα χρηστών, το σύστημα μαθαίνει να αναπαράγει αυτές τις προτιμήσεις εις βάρος άλλων, λιγότερο εκπροσωπούμενων ομάδων (Gao et al., 2023). Τέλος, η κοινωνική μεροληψία (social bias) αναφέρεται στις κοινωνικές ανισότητες ή προκαταλήψεις που περιέχονται στα δεδομένα που χρησιμοποιούνται για την εκπαίδευση των μοντέλων. Όταν τα δεδομένα εμπεριέχουν έμφυλες, φυλετικές ή άλλες διακρίσεις, το σύστημα κινδυνεύει να τις ενισχύσει, προτείνοντας, για παράδειγμα, συγκεκριμένα επαγγέλματα ή προϊόντα αποκλειστικά σε συγκεκριμένες δημογραφικές ομάδες (Gao et al., 2023). Αυτό είναι ιδιαίτερα ανησυχητικό, γιατί επηρεάζει την ισότητα και τη δικαιοσύνη των προτάσεων και, στην πράξη, μειώνει την εμπιστοσύνη των χρηστών προς το σύστημα.

Εν κατακλείδι, η μεροληψία δεν αποτελεί ένα μεμονωμένο τεχνικό πρόβλημα, αλλά μια σύνθετη πρόκληση που συνδέεται στενά με τα δεδομένα, τον σχεδιασμό των αλγορίθμων και το κοινωνικό πλαίσιο χρήσης. Η αντιμετώπισή της απαιτεί προσεκτική ανάλυση των δεδομένων εκπαίδευσης, αλγορίθμους που προωθούν την ποικιλία και τη δικαιοσύνη, καθώς και διαφάνεια ως προς τον τρόπο λειτουργίας των συστημάτων συστάσεων (Adomavicius & Tuzhilin, 2005, Jannach & Jugovac, 2019). Η αντιμετώπιση αυτών των φαινομένων αποτελεί μια από τις πιο ενεργές και κρίσιμες περιοχές της σύγχρονης έρευνας στα RS.

2.4.4. Επεκτασιμότητα και υπολογιστική πολυπλοκότητα

Τα συστήματα συστάσεων αντιμετωπίζουν επίσης προκλήσεις που σχετίζονται με την επεκτασιμότητα (scalability) και την υπολογιστική πολυπλοκότητα (computational complexity). Όπως σημειώνουν οι Alamdari et al. (2020), σε περιβάλλοντα όπου υπάρχουν εκατομμύρια χρήστες και αντικείμενα, η παραγωγή προτάσεων σε πραγματικό χρόνο απαιτεί σημαντικούς υπολογιστικούς πόρους και ιδιαίτερα αποδοτικούς αλγορίθμους. Η ανάγκη για ταχύτητα και ακρίβεια καθιστά απαραίτητη την αξιοποίηση πιο προηγμένων τεχνικών. Η παραγοντοποίηση μητρώων (matrix factorization), για παράδειγμα για την οποία θα γίνει αναφορά παρακάτω στο κεφ 4.2.1, μειώνει τις διαστάσεις του πίνακα αλληλεπιδράσεων χρήστη-αντικειμένου αναπαριστώντας χρήστες και αντικείμενα σε έναν συμπαγή χώρο λανθανόντων χαρακτηριστικών, γεγονός που μειώνει δραστικά την υπολογιστική πολυπλοκότητα (Koren, Bell & Volinsky, 2009). Τα νευρωνικά δίκτυα (neural networks), από την άλλη, επιτρέπουν τη μοντελοποίηση πολύπλοκων, μη γραμμικών σχέσεων και μπορούν να εκπαιδευτούν ώστε να παράγουν προβλέψεις άμεσα, ακόμη και όταν ο όγκος των δεδομένων είναι εξαιρετικά μεγάλος (Gao et al., 2023). Και οι δύο αυτές τεχνικές συμβάλλουν καθοριστικά στη δυνατότητα των συστημάτων συστάσεων να κλιμακώνονται αποτελεσματικά σε εφαρμογές πραγματικού κόσμου, όπου οι χρήστες και τα αντικείμενα μετρούνται σε εκατομμύρια.

2.4.5. Ιδιωτικότητα και προστασία δεδομένων

Ακόμα, ιδιαίτερα σημαντικό ζήτημα αποτελεί η προστασία των προσωπικών δεδομένων και της ιδιωτικότητας των χρηστών. Τα συστήματα συστάσεων βασίζονται σε μεγάλο βαθμό στη συλλογή και επεξεργασία δεδομένων που σχετίζονται με τις προτιμήσεις, τη συμπεριφορά και τις αλληλεπιδράσεις των χρηστών. Η χρήση αυτών των δεδομένων δημιουργεί εύλογες ανησυχίες σχετικά με την ασφάλεια, τη διαφάνεια και τον βαθμό ελέγχου που έχουν οι χρήστες πάνω στις πληροφορίες τους. Για τον λόγο αυτό, η λειτουργία των RS πρέπει να συνοδεύεται από κατάλληλες πολιτικές και τεχνολογίες προστασίας, όπως ανώνυμη συλλογή δεδομένων (anonymization) και αλγόριθμους που διατηρούν την ιδιωτικότητα (privacy-preserving algorithms). Με αυτόν τον τρόπο στόχος είναι η ισορροπία ανάμεσα στην ανάγκη για εξατομίκευση και στην προστασία των δικαιωμάτων των χρηστών.

Συνοψίζοντας, οι προκλήσεις και οι περιορισμοί των recommender systems αναδεικνύουν την πολυπλοκότητα του συγκεκριμένου πεδίου και την ανάγκη για συνεχή βελτίωση των σχετικών μεθοδολογιών. Σύμφωνα με τους Gao et al. (2023) και τους Papadakis et al. (2022), η αντιμετώπιση αυτών των ζητημάτων αποτελεί αντικείμενο έντονης ερευνητικής δραστηριότητας. Οι σύγχρονες προσεγγίσεις επικεντρώνονται κυρίως στη χρήση τεχνητής νοημοσύνης, υβριδικών μοντέλων και τεχνικών που ενισχύουν τη διαφάνεια, την αξιοπιστία και τη δικαιοσύνη των παραγόμενων προτάσεων.

3. ΚΕΦΑΛΑΙΟ 3: Επιχειρησιακή Αξία των Recommender Systems

3.1.Ο Ρόλος των Recommender Systems στο Επιχειρηματικό Μοντέλο

Πέρα από τη λειτουργική τους διάσταση, η οποία αναλύθηκε στο Κεφάλαιο 2, τα RS αποτελούν πλέον βασικό πυλώνα του επιχειρηματικού μοντέλου πολλών ψηφιακών επιχειρήσεων. Τα συστήματα συστάσεων επηρεάζουν τρεις κεντρικές διαστάσεις της επιχειρηματικής λειτουργίας: την αντιληπτή αξία για τον πελάτη, τη σχέση χρήστη-πλατφόρμας και τη στρατηγική θέση της επιχείρησης στην αγορά. Όπως επισημαίνουν οι Ricci et al. (2010), η εξατομίκευση που προσφέρεται ενισχύει την εμπιστοσύνη και την αφοσίωση του χρήστη, ενώ οι Jannach & Jugovac (2019) τεκμηριώνουν ότι η επίδραση αυτή μεταφράζεται σε μετρήσιμα επιχειρηματικά οφέλη, όπως η αύξηση πωλήσεων και η βελτίωση της εμπειρίας χρήστη.

Αναλυτικότερα, στο πλαίσιο του ψηφιακού μετασχηματισμού, τα συστήματα συστάσεων λειτουργούν ως μηχανισμοί εξατομίκευσης, αυτό αποτελεί ένα σημαντικό ανταγωνιστικό πλεονέκτημα. Όπως επισημαίνουν οι Adomavicius και Tuzhilin (2005), επιτρέπουν στις επιχειρήσεις να προσαρμόζουν με δυναμικό τρόπο προϊόντα, υπηρεσίες και επικοινωνία, στις ανάγκες και τις προτιμήσεις κάθε χρήστη. Η δυνατότητα αυτή ενισχύει την εμπειρία του πελάτη, ενώ παράλληλα συμβάλλει στη διαφοροποίηση της επιχείρησης σε αγορές όπου ο ανταγωνισμός είναι ιδιαίτερα έντονος.

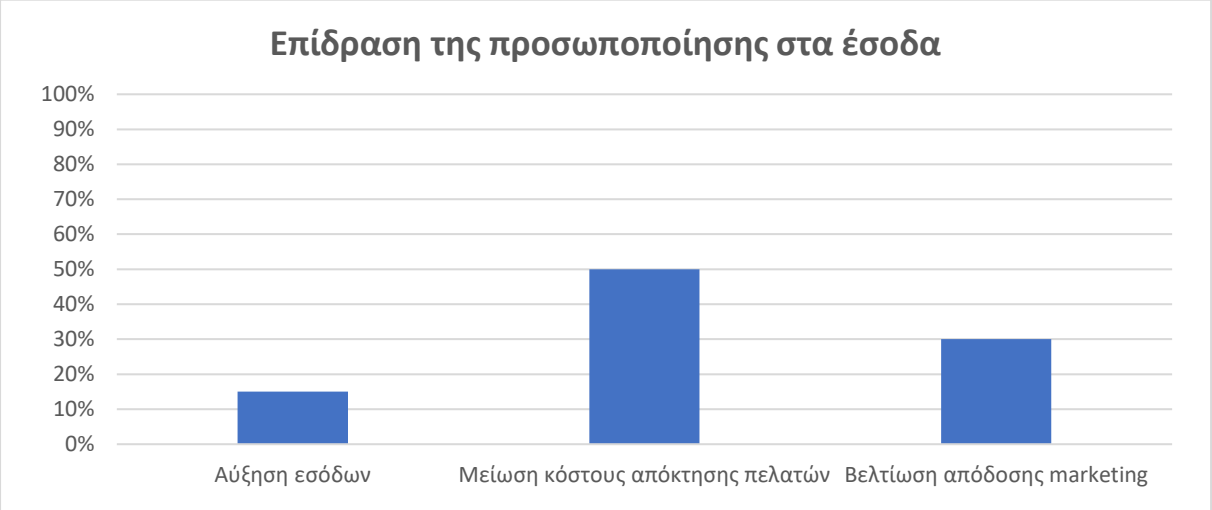
Επίσης, αποτελούν σημαντικό εργαλείο αξιοποίησης δεδομένων, καθώς μετατρέπουν τις αλληλεπιδράσεις των χρηστών σε χρήσιμη επιχειρησιακή πληροφορία. Σύμφωνα με τους Papadakis et al. (2022), η ανάλυση αυτών των δεδομένων επιτρέπει στις επιχειρήσεις να

κατανοούν σε μεγαλύτερο βάθος τη συμπεριφορά των πελατών, να προβλέπουν μελλοντικές ανάγκες και να σχεδιάζουν πιο αποτελεσματικές στρατηγικές marketing και πωλήσεων. Επομένως, τα RS αποτελούν «όπλο» στην φαρέτρα μιας επιχείρησης συμβάλλοντας σημαντικά στη λήψη ευρύτερων στρατηγικών αποφάσεων.

Επιπλέον, ενισχύουν τη δημιουργία αξίας μέσω της αύξησης της δέσμευσης των χρηστών (user engagement). Όπως σημειώνουν οι Jannach και Jugovac (2019), η συνεχής παροχή σχετικού και εξατομικευμένου περιεχομένου μπορεί να οδηγήσει σε μεγαλύτερη διάρκεια παραμονής στις πλατφόρμες, αυξημένη αλληλεπίδραση και υψηλότερα ποσοστά μετατροπής (conversion rates). Οι παράγοντες αυτοί συνδέονται άμεσα με την αύξηση των εσόδων και τη βελτίωση της συνολικής αποδοτικότητας της επιχείρησης.

Τέλος, η στρατηγική σημασία των συστημάτων συστάσεων γίνεται εμφανής και μέσα από τη δυνατότητά τους να υποστηρίζουν καινοτόμα επιχειρηματικά μοντέλα. Σύμφωνα με τους Ricci et al. (2010), χαρακτηριστικά παραδείγματα αποτελούν οι πλατφόρμες συνδρομητικών υπηρεσιών, όπως το Netflix και το Spotify, καθώς και οι αγορές δύο όψεων (two-sided markets), όπως το Amazon Marketplace. Σε τέτοιου είδους περιβάλλοντα, η αποτελεσματική αντιστοίχιση χρηστών με περιεχόμενο, προϊόντα ή υπηρεσίες αποτελεί κρίσιμο παράγοντα για την επιτυχία και τη βιωσιμότητα της πλατφόρμας.

Η στρατηγική σημασία των RS αποτυπώνεται και σε συγκεκριμένα ποσοτικά δεδομένα από την παγκόσμια αγορά. Σύμφωνα με έρευνα της McKinsey & Company (2013), περίπου το 35% των πωλήσεων της Amazon και το 80% των προβολών στο Netflix προέρχονται από αλγοριθμικές προτάσεις. Παράλληλα, μελέτες δείχνουν ότι η προσωποποίηση μπορεί να μειώσει το κόστος απόκτησης πελατών έως και 50%, να αυξήσει τα έσοδα κατά 5% έως 15%, και να βελτιώσει την αποδοτικότητα των δαπανών marketing κατά 10% έως 30% (Jannach & Jugovac, 2019). Τα μεγέθη αυτά καταδεικνύουν ότι η επένδυση σε συστήματα συστάσεων δεν αποτελεί απλώς τεχνολογική επιλογή, αλλά στρατηγική απόφαση με άμεσο οικονομικό αντίκτυπο. Η παραπάνω εικόνα αποτυπώνεται παραστατικά στο Σχεδιάγραμμα 3.1, το οποίο συνοψίζει τις μέσες εκτιμώμενες επιδράσεις της προσωποποίησης σε τρεις κρίσιμους επιχειρησιακούς δείκτες.



Σχεδιάγραμμα 3. 1

Εκτιμώμενη επίδραση της προσωποποίησης σε βασικούς επιχειρησιακούς δείκτες (μέσες τιμές). ***Προσαρμογή από Jannach & Jugovac (2019)***

3.2.Επιρροή των Recommender Systems στην Αγοραστική Εμπειρία

Η αγοραστική εμπειρία στο ψηφιακό περιβάλλον έχει μετασχηματιστεί σημαντικά μέσα από την ενσωμάτωση των συστημάτων συστάσεων. Σε ένα περιβάλλον όπου οι διαθέσιμες επιλογές είναι σχεδόν απεριόριστες, η εξατομίκευση της πληροφορίας δεν αποτελεί απλώς μια πρόσθετη λειτουργία, αλλά έναν κρίσιμο μηχανισμό που διευκολύνει τη λήψη αποφάσεων και βελτιώνει τη συνολική εμπειρία του χρήστη (Pu et al., 2012, Bleier & Eisenbeiss, 2015).

Πρωτίστως, τα συστήματα συστάσεων συμβάλλουν ουσιαστικά στη μείωση της γνωστικής επιβάρυνσης (cognitive load) που αντιμετωπίζει ο χρήστης κατά την αναζήτηση και επιλογή προϊόντων ή υπηρεσιών. Αυτό επιτυγχάνεται παρέχοντας στοχευμένες προτάσεις, οι οποίες ανταποκρίνονται στις ανάγκες, τις προτιμήσεις και τη συμπεριφορά του, έτσι περιορίζεται η ανάγκη για εκτεταμένη αναζήτηση και σύγκριση πολλών εναλλακτικών επιλογών. Όπως επισημαίνουν οι Xiao και Benbasat (2007), το αποτέλεσμα είναι μια ταχύτερη και πιο αποτελεσματική διαδικασία επιλογής. Επιπροσθέτως, η παροχή σχετικών και προσωποποιημένων προτάσεων ενισχύει την χρησιμότητα του συστήματος και αυξάνει τον βαθμό ικανοποίησης του χρήστη. Πέραν αυτού, η εξατομίκευση που προσφέρουν τα RS μπορεί επίσης να ενισχύσει τη συναισθηματική σύνδεση του χρήστη με την πλατφόρμα. Όταν οι προτάσεις γίνονται αντιληπτές ως σχετικές και ουσιαστικές, ο χρήστης έχει την αίσθηση

ότι το σύστημα «κατανοεί» καλύτερα τις ανάγκες και τις προτιμήσεις του. Η αντίληψη αυτή ενισχύει την εμπιστοσύνη προς το σύστημα και αυξάνει την πιθανότητα επαναλαμβανόμενης χρήσης (Komiak & Benbasat, 2006). Κατά συνέπεια χτίζονται μακροχρόνιες σχέσεις ανάμεσα στον πελάτη και την επιχείρηση, καθώς όσο περισσότερο ο χρήστης αισθάνεται ότι η πλατφόρμα του προσφέρει σχετικό και χρήσιμο περιεχόμενο, τόσο αυξάνεται η πιθανότητα να επιστρέψει και να συνεχίσει να αλληλεπιδρά με αυτή.

Ακόμα, τα συστήματα συστάσεων επηρεάζουν σημαντικά τη συμπεριφορά πλοήγησης των χρηστών. Μέσα από τη δυναμική προβολή σχετικού περιεχομένου, οι χρήστες εκτίθενται σε προϊόντα ή υπηρεσίες που πιθανότατα δεν θα αναζητούσαν από μόνοι τους (Schafer et al., 2001, Anderson, 2006). Με αυτόν τον τρόπο, ενισχύεται η εξερεύνηση και η ανακάλυψη νέων επιλογών (discoverability), μια διάσταση που θεωρείται κρίσιμη για τη συνολική ποιότητα της εμπειρίας χρήστη (Pu, Chen & Hu, 2012).

Πάρα ταύτα, η επίδραση των συστημάτων συστάσεων στην αγοραστική εμπειρία δεν είναι πάντοτε αποκλειστικά θετική. Σύμφωνα με τους Nguyen et al. (2014), όταν οι προτάσεις γίνονται επαναλαμβανόμενες ή περιορίζονται σε ένα πολύ στενό σύνολο αντικειμένων, μπορεί να εμφανιστεί το φαινόμενο της υπερ-εξειδίκευσης (over-specialization). Στην περίπτωση αυτή, το σύστημα προτείνει συνεχώς παρόμοιες επιλογές, περιορίζοντας την ποικιλία και ενδεχομένως μειώνοντας την ικανοποίηση του χρήστη. Συμπληρωματικά, η υπερβολική εξάρτηση από αλγοριθμικές προτάσεις μπορεί να επηρεάσει την αυτονομία του χρήστη στη διαδικασία λήψης αποφάσεων (Adomavicius & Tuzhilin, 2005). Όταν ο χρήστης βασίζεται σε μεγάλο βαθμό στις προτάσεις του συστήματος, υπάρχει ο κίνδυνος να περιοριστεί η αίσθηση ελέγχου του πάνω στις επιλογές του. Για τον λόγο αυτό, είναι σημαντικό τα συστήματα συστάσεων να σχεδιάζονται με τρόπο που να υποστηρίζει τη λήψη αποφάσεων, χωρίς να περιορίζει την ελευθερία και την ποικιλία των επιλογών.

Συμπερασματικά, τα recommender systems διαδραματίζουν καθοριστικό ρόλο στη διαμόρφωση της αγοραστικής εμπειρίας στο ψηφιακό περιβάλλον. Μέσω της εξατομίκευσης, της μείωσης της πολυπλοκότητας και της ενίσχυσης της εμπιστοσύνης, συμβάλλουν στη δημιουργία μιας πιο αποδοτικής, ευχάριστης και λειτουργικής εμπειρίας για τον χρήστη. Ωστόσο, η αποτελεσματική αξιοποίησή τους προϋποθέτει ισορροπία ανάμεσα στην ακρίβεια και την ποικιλία των προτάσεων, ώστε να αποφεύγονται φαινόμενα υπερβολικής εξειδίκευσης που μπορούν να περιορίσουν τα θετικά τους αποτελέσματα.

3.3.Ενίσχυση Πωλήσεων και Προσωποποίηση Υπηρεσιών

Όπως αναφέρθηκε παραπάνω στο Κεφ 3.1, τα συστήματα συστάσεων μέσα από την αξιοποίηση δεδομένων και αλγοριθμικών μοντέλων, επιτρέπουν στις επιχειρήσεις να προσαρμόζουν την αξία που προσφέρουν στις ιδιαίτερες ανάγκες, προτιμήσεις και συμπεριφορές κάθε χρήστη. Ειδικότερα, όπως επισημαίνουν οι Alamdari et al. (2020) και οι Schafer et al. (2001), η ανάλυση δεδομένων συμπεριφοράς δίνει τη δυνατότητα στις επιχειρήσεις να προτείνουν προϊόντα και υπηρεσίες που παρουσιάζουν υψηλότερη πιθανότητα αποδοχής από τον καταναλωτή.

Κατ' αρχάς, βασικό πυρήνα της λειτουργίας των RS αποτελεί η προσωποποίηση. Σε αντίθεση με τις παραδοσιακές μαζικές προσεγγίσεις marketing, οι οποίες απευθύνονται σε ευρύτερες ομάδες καταναλωτών με ενιαία μηνύματα, τα συστήματα συστάσεων επιτρέπουν την παροχή εξατομικευμένων προτάσεων σε πραγματικό χρόνο. Οι προτάσεις αυτές βασίζονται στο ιστορικό πλοήγησης, στις προηγούμενες αγορές, στις αξιολογήσεις και στα γενικότερα μοτίβα συμπεριφοράς του χρήστη (Tam & Ho, 2006). Με αυτόν τον τρόπο, ενισχύεται η αντιλαμβανόμενη συνάφεια των προτάσεων, καθώς ο χρήστης εκτίθεται σε επιλογές που φαίνεται να ανταποκρίνονται πιο άμεσα στις ανάγκες και τα ενδιαφέροντά του. Η αυξημένη συνάφεια μπορεί, με τη σειρά της, να οδηγήσει σε μεγαλύτερη πιθανότητα μετατροπής (conversion rate), δηλαδή σε αύξηση της πιθανότητας ο χρήστης να ολοκληρώσει μια αγορά ή μια άλλη επιθυμητή ενέργεια.

Στη συνέχεια, η επιτακτική συμβολή τους στον χώρο του ηλεκτρονικού εμπορίου σχετικά με την αύξηση των πωλήσεων είναι ιδιαίτερα εμφανής. Όπως αναφέρουν οι Linden et al. (2003), ένα σημαντικό μέρος των εσόδων μεγάλων ψηφιακών πλατφορμών, όπως η Amazon, συνδέεται στενά με τη χρήση εξατομικευμένων προτάσεων. Το γεγονός αυτό αναδεικνύει τη στρατηγική σημασία των RS στη διαμόρφωση της ζήτησης και στην καθοδήγηση της αγοραστικής συμπεριφοράς.

Επιπλέον, η δυνατότητα πρότασης συναφών ή συμπληρωματικών προϊόντων συμβάλλει στην αύξηση του μέσου καλαθιού αγορών (average order value). Για παράδειγμα, όταν ένα σύστημα προτείνει προϊόντα που συμπληρώνουν την αρχική επιλογή του χρήστη ή ανταποκρίνονται σε παρόμοιες ανάγκες, αυξάνεται η πιθανότητα πρόσθετων αγορών. Έτσι, τα recommender systems δεν επηρεάζουν μόνο την ολοκλήρωση μιας αγοράς, αλλά και τη συνολική αξία της συναλλαγής.

Ακόμα, τα συστήματα συστάσεων συμβάλλουν στην ανάπτυξη πιο αποδοτικών στρατηγικών marketing, καθώς επιτρέπουν τη στόχευση συγκεκριμένων ομάδων χρηστών με προσωποποιημένο περιεχόμενο. Σύμφωνα με τους Bleier και Eisenbeiss (2015), η αξιοποίηση δεδομένων μπορεί να υποστηρίξει τη δημιουργία πιο προφίλ πελατών με μεγαλύτερη ακρίβεια, την προσαρμογή προσφορών, διαφημίσεων και μηνυμάτων επικοινωνίας, καθώς και τη βελτίωση της αποτελεσματικότητας των διαφημιστικών καμπανιών. Με αυτόν τον τρόπο, οι επιχειρήσεις μπορούν να αξιοποιούν καλύτερα τους διαθέσιμους πόρους τους, μειώνοντας τις μη στοχευμένες ενέργειες και αυξάνοντας την πιθανότητα ανταπόκρισης από τους χρήστες. Η προσωποποιημένη επικοινωνία καθιστά το marketing πιο σχετικό, πιο άμεσο και, σε πολλές περιπτώσεις, πιο αποτελεσματικό.

Ιδιαίτερη έμφαση πρέπει να δοθεί στο γεγονός πως η προσωποποίηση που προσφέρεται από τα RS δεν περιορίζεται αποκλειστικά στην πρόταση προϊόντων. Όπως σημειώνουν οι Jannach και Jugovac (2019), μπορεί να επεκταθεί στη συνολική εμπειρία του χρήστη μέσα στην πλατφόρμα. Αυτό περιλαμβάνει στοιχεία όπως η διάταξη της σελίδας (layout), η σειρά εμφάνισης του περιεχομένου, οι προτεινόμενες κατηγορίες, οι προσφορές που εμφανίζονται και ο γενικότερος τρόπος αλληλεπίδρασης με το σύστημα. Η προσαρμογή αυτών των στοιχείων στις προτιμήσεις και στη συμπεριφορά του χρήστη ενισχύει την αίσθηση εξατομίκευσης και δημιουργεί ένα πιο ελκυστικό, λειτουργικό και φιλικό περιβάλλον.

Ωστόσο, η εντατική χρήση της προσωποποίησης συνοδεύεται και από ορισμένες προκλήσεις. Σύμφωνα με τους Nguyen et al. (2014), η υπερβολική εστίαση στις ήδη καταγεγραμμένες προτιμήσεις του χρήστη μπορεί να οδηγήσει σε περιορισμό της ποικιλίας των προτάσεων και να ενισχύσει φαινόμενα αλγοριθμικής κλειστότητας, όπως αναλύεται εκτενέστερα στην ενότητα 3.5. Το αποτέλεσμα είναι ο συστηματικός περιορισμός της έκθεσης σε νέες κατηγορίες επιλογών. Για τον λόγο αυτό, η αποτελεσματική αξιοποίηση των recommender systems απαιτεί ισορροπία ανάμεσα στην ακρίβεια και τη ποικιλία των προτάσεων. Τα συστήματα πρέπει να είναι αρκετά ακριβή ώστε να ανταποκρίνονται στις ανάγκες του χρήστη, αλλά και αρκετά ευέλικτα ώστε να προσφέρουν ποικιλία και ευκαιρίες ανακάλυψης.

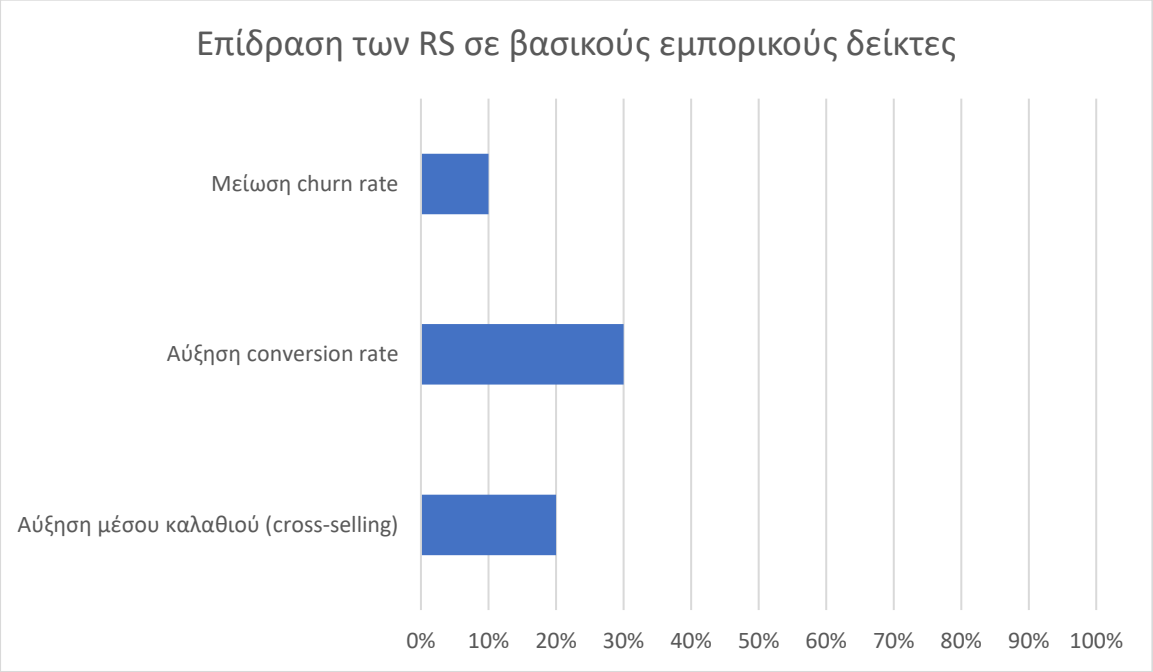
Συμπερασματικά, τα recommender systems διαδραματίζουν καθοριστικό ρόλο στην ενίσχυση των πωλήσεων και στην προσωποποίηση των υπηρεσιών. Αποτελούν βασικό εργαλείο δημιουργίας αξίας στο σύγχρονο επιχειρηματικό περιβάλλον, καθώς επιτρέπουν στις επιχειρήσεις να αυξάνουν τα έσοδά τους, να βελτιώνουν την εμπειρία των πελατών και να ενισχύουν τη θέση τους στην αγορά. Η στρατηγική αξιοποίησή τους, ωστόσο, απαιτεί

προσεκτικό σχεδιασμό, ώστε να διατηρείται η ισορροπία ανάμεσα στην αποτελεσματικότητα των προτάσεων και στην ποιότητα της εμπειρίας του χρήστη.

3.4.Εμπορικά Οφέλη: Διατήρηση Πελατών, Upselling και Cross-Selling

Η αξιοποίηση των συστημάτων συστάσεων συνδέεται άμεσα με εμπορικά οφέλη που δεν περιορίζονται μόνο στην αύξηση των πωλήσεων. Σύμφωνα με τους Schafer et al. (2001) και τους Jannach και Jugovac (2019), τα οφέλη αυτά μπορούν να εντοπιστούν σε τρεις βασικούς άξονες: στη διατήρηση πελατών (customer retention), στη μεγιστοποίηση της αξίας κάθε συναλλαγής μέσω στρατηγικών upselling και cross selling, καθώς και στη συνολική ενίσχυση της κερδοφορίας. Υπό αυτή την έννοια, τα RS λειτουργούν ως μηχανισμοί στρατηγικής στόχευσης, καθώς επιτρέπουν στις επιχειρήσεις να προσεγγίζουν τους πελάτες τους με μεγαλύτερη ακρίβεια και αποτελεσματικότητα.

Η αποτελεσματικότητα αυτή αποτυπώνεται σε μια σειρά από εμπειρικά δεδομένα. Οι επιχειρήσεις που αξιοποιούν RS για cross-selling βλέπουν αύξηση του μέσου καλαθιού αγορών κατά 10% έως 30%, ενώ οι προσωποποιημένες προτάσεις μπορούν να οδηγήσουν σε αύξηση του conversion rate κατά 20% έως 40% (Jannach & Jugovac, 2019). Επιπλέον, η χρήση RS για customer retention έχει συνδεθεί με μείωση του churn rate κατά 5% έως 15%, γεγονός που μεταφράζεται σε σημαντική εξοικονόμηση κόστους για πλατφόρμες συνδρομητικού χαρακτήρα (Gomez-Uribe & Hunt, 2015). Τα νούμερα αυτά αναδεικνύουν τη μετρήσιμη αξία που μπορούν να προσφέρουν τα RS όταν ενσωματώνονται στρατηγικά στις επιχειρησιακές διαδικασίες. Οι τάσεις αυτές απεικονίζονται συνοπτικά στο Σχεδιλαγραμμα 3.2, το οποίο παρουσιάζει τις μέσες εκτιμώμενες βελτιώσεις σε τρεις βασικούς εμπορικούς δείκτες που συνδέονται άμεσα με τη χρήση συστημάτων συστάσεων.



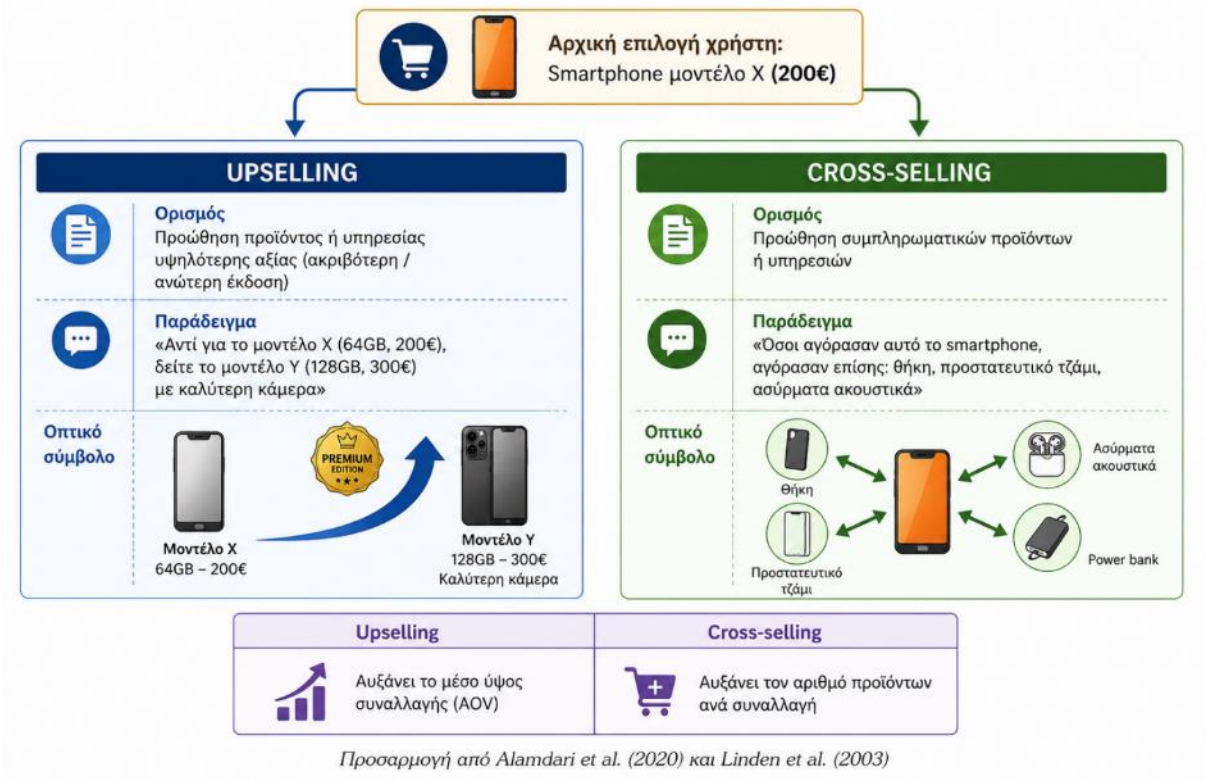
Σχεδιάγραμμα 3. 2

Εκτιμώμενη επίδραση των RS σε βασικούς εμπορικούς δείκτες (μέσες τιμές). Προσαρμογή από Jannach & Jugovac (2019) και Gomez-Uribe & Hunt (2015).

Ένα από τα σημαντικότερα οφέλη των συστημάτων συστάσεων είναι η ενίσχυση της διατήρησης πελατών. Όπως αναφέρθηκε παραπάνω, μέσα από τη συνεχή παροχή σχετικών και εξατομικευμένων προτάσεων, οι χρήστες βιώνουν μια πιο ολοκληρωμένη και ικανοποιητική εμπειρία. Αυτό αυξάνει την πιθανότητα επαναλαμβανόμενης χρήσης της πλατφόρμας και ενισχύει τη σχέση τους με την επιχείρηση. Όπως επισημαίνουν οι Komiak και Benbasat (2006), η ενίσχυση της εμπιστοσύνης και η αίσθηση ότι το σύστημα «κατανοεί» τις ανάγκες του χρήστη συμβάλλουν στη δημιουργία μακροχρόνιων σχέσεων μεταξύ επιχείρησης και πελάτη. Επίσης, υποστηρίζουν αποτελεσματικά στρατηγικές upselling, δηλαδή την προώθηση προϊόντων ή υπηρεσιών υψηλότερης αξίας σε σχέση με την αρχική επιλογή του χρήστη. Σύμφωνα με τους Alamdari et al. (2020), μέσα από την ανάλυση των προτιμήσεων και την πρόβλεψη της αγοραστικής συμπεριφοράς, τα συστήματα μπορούν να προτείνουν εναλλακτικές επιλογές που ανταποκρίνονται καλύτερα στις ανάγκες του χρήστη και, ταυτόχρονα, αυξάνουν το μέσο ύψος της συναλλαγής (average order value - AOV). Εξίσου σημαντική είναι η συμβολή των συστημάτων συστάσεων στις στρατηγικές cross selling, οι οποίες αφορούν την προώθηση συμπληρωματικών προϊόντων ή υπηρεσιών. Σύμφωνα με τους Linden et al. (2003), η δυναμική πρόταση σχετικών αντικειμένων, μέσα

από πρακτικές όπως «όσοι αγόρασαν αυτό, αγόρασαν επίσης...» ή «συχνά αγοράζονται μαζί», αυξάνει την πιθανότητα πρόσθετων αγορών. Η πρακτική αυτή είναι ιδιαίτερα διαδεδομένη σε πλατφόρμες ηλεκτρονικού εμπορίου, όπως η Amazon, και συμβάλλει σημαντικά στην αύξηση των συνολικών εσόδων.

Η διάκριση μεταξύ upselling και cross selling παρουσιάζεται στο Σχεδιάγραμμα 3.3.



Σχεδιάγραμμα 3. 3

Διάκριση μεταξύ upselling και cross-selling στα συστήματα συστάσεων. Το upselling προωθεί μια ακριβότερη ή ανώτερη έκδοση του ίδιου προϊόντος, ενώ το cross-selling προτείνει συμπληρωματικά προϊόντα. Και οι δύο στρατηγικές συμβάλλουν στην αύξηση των εσόδων. *Προσαρμογή από Alamdari et al. (2020) και Linden et al. (2003).*

Επιπλέον, τα recommender systems επιτρέπουν την αποτελεσματικότερη αξιοποίηση του διαθέσιμου καταλόγου προϊόντων ή υπηρεσιών. Δεν περιορίζονται μόνο στην προώθηση των πιο δημοφιλών αντικειμένων, αλλά μπορούν να αναδείξουν και λιγότερο προβεβλημένα προϊόντα, τα οποία ανήκουν στη λεγόμενη «μακρά ουρά» (long tail). Η δυνατότητα αυτή συμβάλλει στην καλύτερη κατανομή της ζήτησης, στη βελτίωση της αποδοτικότητας της διαχείρισης αποθεμάτων και στη μείωση του κινδύνου παραμονής απούλητων ειδών

(Anderson, 2006). Εντούτοις, η επιτυχία των στρατηγικών upselling και cross selling εξαρτάται σε μεγάλο βαθμό από την ποιότητα των προτάσεων και από την ισορροπία ανάμεσα στο πόσο σχετικές είναι οι προτάσεις με αυτό που πραγματικά θέλει ο χρήστης και την ποικιλία επιλογών (Jannach & Jugovac, 2019). Προτάσεις που είναι υπερβολικά επιθετικές, επαναλαμβανόμενες ή μη σχετικές με τις πραγματικές ανάγκες του χρήστη μπορούν να έχουν το αντίθετο αποτέλεσμα, οδηγώντας σε μείωση της αποτελεσματικότητας των εμπορικών ενεργειών (Bleier & Eisenbeiss, 2015). Σε τέτοιες περιπτώσεις, είναι πιθανό να δημιουργηθεί αρνητική εμπειρία χρήστη και να υπονομευθεί η εμπιστοσύνη προς την πλατφόρμα (Komiak & Benbasat, 2006).

Συνεπώς, η σωστή ρύθμιση των αλγορίθμων και η συνεχής αξιολόγηση της απόδοσής τους αποτελούν κρίσιμους παράγοντες για τη μεγιστοποίηση των εμπορικών οφελών. Πρακτικές όπως το A/B testing, η σύγκριση δηλαδή δύο εκδοχών ενός αλγορίθμου ή μιας διάταξης προτάσεων ώστε να διαπιστωθεί ποια αποδίδει καλύτερα σε πραγματικές συνθήκες, η παρακολούθηση των conversion rates και η ανάλυση της συμπεριφοράς των χρηστών μπορούν να συμβάλουν στη βελτίωση της ποιότητας των προτάσεων και στη διατήρηση μιας ισορροπημένης εμπειρίας (Jannach & Jugovac, 2019).

Συνολικά, τα recommender systems συνιστούν ένα ισχυρό εργαλείο ενίσχυσης της εμπορικής απόδοσης. Υποστηρίζουν τη διατήρηση πελατών, την αύξηση της αξίας των συναλλαγών μέσω upselling και cross selling (Schafer, Konstan & Riedl, 2001), καθώς και τη βελτιστοποίηση της αξιοποίησης του διαθέσιμου καταλόγου, συμπεριλαμβανομένης της ανάδειξης λιγότερο δημοφιλών προϊόντων της «μακράς ουράς» (Anderson, 2006). Η στρατηγική ενσωμάτωσή τους συμβάλλει καθοριστικά στη δημιουργία ανταγωνιστικού πλεονεκτήματος στο σύγχρονο ψηφιακό περιβάλλον.

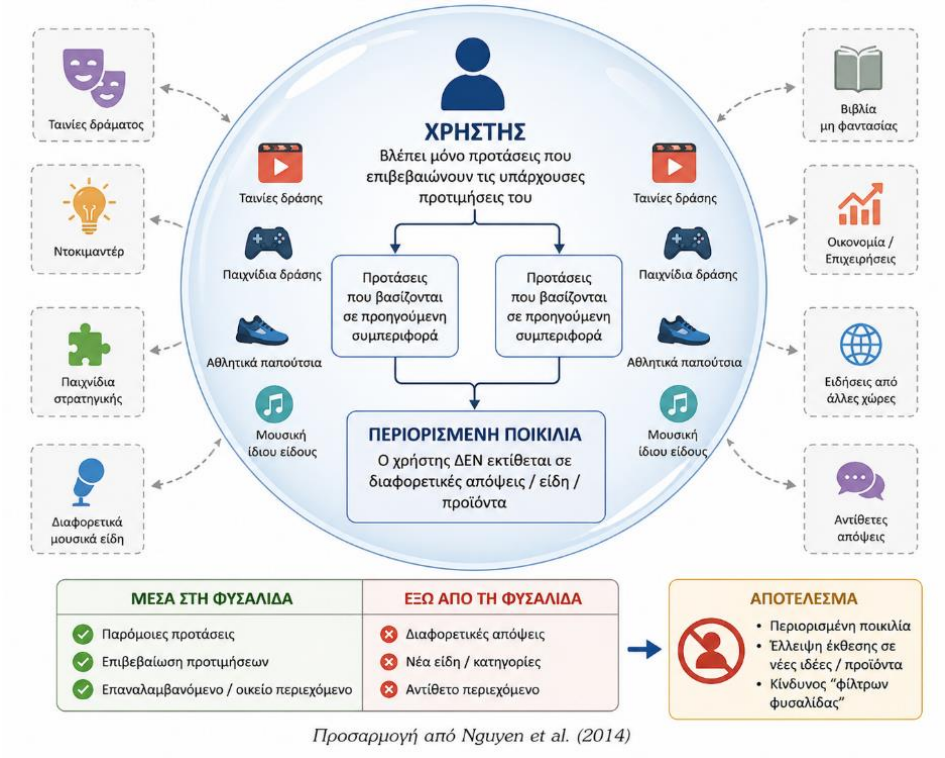
3.5.Πιθανοί Κίνδυνοι – Λάθος Προτάσεις και Απώλεια Εμπιστοσύνης

Παρά τα σημαντικά οφέλη που προσφέρουν, τα συστήματα συστάσεων συνοδεύονται και από ορισμένους κινδύνους, οι οποίοι μπορούν να επηρεάσουν αρνητικά τόσο την εμπειρία του χρήστη όσο και τη σχέση του με την επιχείρηση Οι κίνδυνοι αυτοί σχετίζονται κυρίως με την ακρίβεια (accuracy) των προτάσεων, την ποιότητα των δεδομένων που αξιοποιούνται και τον τρόπο με τον οποίο οι χρήστες αντιλαμβάνονται την αξιοπιστία του συστήματος (Ricci et al., 2010, Jannach & Jugovac, 2019).

Ένας από τους βασικότερους παράγοντες κινδύνου είναι η παραγωγή λανθασμένων ή μη σχετικών προτάσεων. Όταν ένα recommender system δεν καταφέρνει να αποτυπώσει σωστά τις προτιμήσεις του χρήστη ή βασίζεται σε ελλιπή, ανακριβή ή θορυβώδη δεδομένα, οι προτάσεις που παράγει μπορεί να είναι άστοχες ή ακόμη και παραπλανητικές. Σε τέτοιες περιπτώσεις, ο χρήστης ενδέχεται να θεωρήσει ότι το σύστημα δεν ανταποκρίνεται πραγματικά στις ανάγκες του. Αυτό μειώνει την αντιλαμβανόμενη αξία του συστήματος και μπορεί να οδηγήσει σε σταδιακή αποδυνάμωση της εμπιστοσύνης προς την πλατφόρμα ή την επιχείρηση (Adomavicius & Tuzhilin, 2005). Σύμφωνα με το μοντέλο εμπιστοσύνης των Hoff και Bashir (2015), η εμπιστοσύνη ενός χρήστη προς ένα σύστημα συστάσεων διαμορφώνεται σε τρία επίπεδα: την προσωπική του προδιάθεση (dispositional), τις περιστασιακές συνθήκες (situational), και την επίκτητη εμπειρία του (learned) μέσα από τη χρήση του συστήματος. Στο πλαίσιο αυτό, η εμπιστοσύνη προς ένα RS συνδέεται με τρεις βασικές διαστάσεις: την αξιοπιστία, δηλαδή το κατά πόσο οι προτάσεις θεωρούνται σωστές και χρήσιμες, τη διαφάνεια, δηλαδή το κατά πόσο ο χρήστης μπορεί να κατανοήσει γιατί του προτάθηκε κάτι και τη συνέπεια, δηλαδή το κατά πόσο το σύστημα εμφανίζει σταθερή και προβλέψιμη συμπεριφορά. Η διαφάνεια ενισχύει την εμπιστοσύνη μέσω δύο βασικών μηχανισμών: αφενός αυξάνει την αντιλαμβανόμενη αποτελεσματικότητα του συστήματος, καθώς ο χρήστης πιστεύει ότι το βοηθά να λάβει καλύτερες αποφάσεις, και αφετέρου μειώνει το αίσθημα δυσφορίας που προκαλεί η αίσθηση ενός «μαύρου κουτιού» (Adomavicius & Tuzhilin, 2005). Όταν οι χρήστες διαπιστώνουν επαναλαμβανόμενα λάθη ή λαμβάνουν προτάσεις που δεν σχετίζονται με τα ενδιαφέροντα και τις ανάγκες τους, είναι πιθανό να αρχίσουν να αγνοούν τις συστάσεις. Σε πιο έντονες περιπτώσεις, μπορεί ακόμη και να εγκαταλείψουν τη χρήση της πλατφόρμας, γεγονός που επηρεάζει αρνητικά τόσο την εμπειρία χρήστη όσο και τη σχέση πελάτη - επιχείρησης (Komiak & Benbasat, 2006).

Ένας ακόμη σημαντικός κίνδυνος είναι η δημιουργία του λεγόμενου «φαινομένου φίλτρου» (filter bubble), το οποίο συνδέεται με την υπερβολική εξάρτηση από αλγοριθμικές προτάσεις. Στην περίπτωση αυτή, οι χρήστες εκτίθενται κυρίως σε περιεχόμενο, προϊόντα ή υπηρεσίες που επιβεβαιώνουν τις ήδη διαμορφωμένες προτιμήσεις τους. Το αποτέλεσμα είναι ο περιορισμός της ποικιλίας των επιλογών, η μείωση της πιθανότητας ανακάλυψης νέων προϊόντων ή υπηρεσιών και η περαιτέρω ενίσχυση των υφιστάμενων προτιμήσεων του χρήστη. Όπως επισημαίνουν οι Nguyen et al. (2014), το φαινόμενο αυτό μπορεί να περιορίσει την εξερεύνηση και να οδηγήσει σε μια πιο κλειστή και λιγότερο πλούσια εμπειρία χρήστη.

Ένας επιπλέον κίνδυνος αφορά την ακεραιότητα των δεδομένων από κακόβουλες ενέργειες, όπως οι *shilling attacks*, δηλαδή συντονισμένες προσπάθειες χειραγώγησης των βαθμολογιών για την τεχνητή προώθηση ή υποτίμηση προϊόντων (Burke et al., 2005). Πέραν της εξωτερικής παρέμβασης, τα συστήματα συστάσεων δυσκολεύονται επίσης να εξυπηρετήσουν τους λεγόμενους «Gray Sheep», χρήστες δηλαδή με τόσο μοναδικά γούστα που δεν ταιριάζουν ξεκάθαρα σε καμία ομάδα, με αποτέλεσμα να λαμβάνουν συχνά αδιάφορες ή άστοχες προτάσεις (Claypool et al., 1999).



Προσαρμογή από Nguyen et al. (2014)

Σχεδιάγραμμα 3. 4

Η λειτουργία του φαινομένου «φίλτρου φυσαλίδας» (filter bubble) σε συστήματα συστάσεων. Η υπερβολική εξατομίκευση απομονώνει τον χρήστη από διαφορετικές απόψεις, περιορίζοντας την ποικιλία και την έκθεση σε νέες επιλογές. *Προσαρμογή από Nguyen et al. (2014).*

Ως μια ακόμη πρόκληση αξίζει να αναφερθεί, η μεροληψία των αλγορίθμων και των δεδομένων που χρησιμοποιούνται για την εκπαίδευσή τους, για την οποία υπάρχει εκτενής αναφορά ανωτέρω στο κεφάλαιο 2.4.3, . Εδώ, τα RS μπορούν να ενισχύσουν ήδη υπάρχουσες ανισορροπίες, προωθώντας δυσανάλογα συγκεκριμένα προϊόντα, υπηρεσίες ή ομάδες αντικειμένων, ενώ παράλληλα περιορίζουν την ορατότητα λιγότερο δημοφιλών επιλογών.

Η μεροληψία αυτή μπορεί να έχει αρνητικές συνέπειες τόσο για τους χρήστες όσο και για τις επιχειρήσεις. Για τους χρήστες, μπορεί να οδηγήσει σε μειωμένη ποικιλία προτάσεων και σε περιορισμένη αντικειμενικότητα κατά τη διαδικασία επιλογής. Για τις επιχειρήσεις, αντίστοιχα, μπορεί να περιορίσει τη διαφοροποίηση, την καινοτομία και τη δυνατότητα ανάδειξης νέων ή λιγότερο γνωστών προϊόντων και υπηρεσιών (Gao et al., 2023).

Ιδιαίτερη σημασία έχουν και ζητήματα που σχετίζονται με την προστασία των προσωπικών δεδομένων και την ιδιωτικότητα των χρηστών και μπορούν να επηρεάσουν σημαντικά την εμπιστοσύνη προς τα συστήματα συστάσεων. Η λειτουργία των RS βασίζεται σε μεγάλο βαθμό στη συλλογή και επεξεργασία δεδομένων συμπεριφοράς, όπως ιστορικό πλοήγησης, αγορές, αξιολογήσεις και προτιμήσεις. Η εκτεταμένη χρήση αυτών των δεδομένων δημιουργεί ανησυχίες σχετικά με τον τρόπο αξιοποίησης των πληροφοριών, τη διαφάνεια των διαδικασιών και τον βαθμό ελέγχου που διατηρεί ο ίδιος ο χρήστης πάνω στα προσωπικά του δεδομένα. Σε ορισμένες περιπτώσεις, η υπερ-εξατομίκευση μπορεί να εκληφθεί ως παρεμβατική, δημιουργώντας αυτό που στη βιβλιογραφία αναφέρεται ως «creepiness factor» και υπονομεύοντας την εμπιστοσύνη αντί να την ενισχύει (Komiak & Benbasat, 2006). Ιδιαίτερα κρίσιμος είναι ο Γενικός Κανονισμός για την Προστασία Δεδομένων (General Data Protection Regulation - GDPR) της Ευρωπαϊκής Ένωσης, ο οποίος θέτει αυστηρές απαιτήσεις για τη συλλογή, την επεξεργασία και την αποθήκευση προσωπικών δεδομένων, επηρεάζοντας άμεσα τον τρόπο με τον οποίο τα συστήματα συστάσεων διαχειρίζονται τις πληροφορίες των χρηστών (Tejeda-Lorente et al., 2018). Η μη συμμόρφωση με τέτοιους κανονισμούς, ή η έλλειψη διαφάνειας στη διαχείριση των δεδομένων, μπορεί να πλήξει σοβαρά την εμπιστοσύνη των χρηστών προς το σύστημα και την πλατφόρμα (Komiak & Benbasat, 2006). Πέρα από τον GDPR, το νέο ρυθμιστικό πλαίσιο της Ευρωπαϊκής Ένωσης για την Τεχνητή Νοημοσύνη (EU AI Act) εισάγει πρόσθετες απαιτήσεις για συστήματα που επηρεάζουν σημαντικά τους χρήστες, ενισχύοντας την ανάγκη για διαφάνεια και ανθρώπινη επίβλεψη (European Commission, 2021).

Ακόμα, η έλλειψη σαφούς ενημέρωσης ή ουσιαστικού ελέγχου των δεομένων που συλλέγονται μπορεί να οδηγήσει σε αρνητική στάση απέναντι στο σύστημα και να μειώσει την προθυμία του χρήστη να αλληλεπιδράσει με αυτό. Επομένως, η προστασία της ιδιωτικότητας δεν αποτελεί μόνο τεχνικό ή νομικό ζήτημα, αλλά και βασική προϋπόθεση για τη διατήρηση της εμπιστοσύνης των χρηστών (Adomavicius & Tuzhilin, 2005). Επομένως, δημιουργείται η επιτακτική ανάγκη για αξιόπιστα και διαφανή συστήματα.

Συνολικά, οι κίνδυνοι που σχετίζονται με τα recommender systems αναδεικνύουν τη σημασία της ορθής σχεδίασης, της συνεχούς αξιολόγησης και της διασφάλισης της ποιότητας των δεδομένων. Η αποτελεσματική λειτουργία των συστημάτων συστάσεων δεν εξαρτάται μόνο από την ακρίβεια των προτάσεων, αλλά και από τον βαθμό στον οποίο τα συστήματα αυτά είναι αξιόπιστα, διαφανή και σεβαστά απέναντι στον χρήστη. Η ανάπτυξη συστημάτων που λαμβάνουν υπόψη τόσο την τεχνική απόδοση όσο και την εμπειρία, την αυτονομία και την εμπιστοσύνη του χρήστη αποτελεί βασική προϋπόθεση για την επιτυχή ενσωμάτωση των RS στο επιχειρηματικό περιβάλλον. Με αυτόν τον τρόπο, οι επιχειρήσεις μπορούν να αξιοποιήσουν τα οφέλη της εξατομίκευσης, περιορίζοντας παράλληλα τους κινδύνους που ενδέχεται να υπονομεύσουν τη σχέση τους με τους πελάτες. Η διαχείριση αυτών των κινδύνων, ιδιαίτερα μέσω της ανάπτυξης διαφανών και ερμηνεύσιμων συστημάτων, παραμένει κεντρικό ζητούμενο τόσο για την ακαδημαϊκή κοινότητα όσο και για τις επιχειρήσεις

4. ΚΕΦΑΛΑΙΟ 4: Σύγχρονες Τεχνολογικές Τάσεις και AI στα Recommender Systems

4.1. Τεχνητή Νοημοσύνη και Recommender Systems

Η εξέλιξη των συστημάτων συστάσεων είναι στενά συνδεδεμένη με την πρόοδο της τεχνητής νοημοσύνης (Artificial Intelligence - AI). Όπως επισημαίνουν οι Ricci et al. (2010) και οι Jannach και Jugovac (2019), η τεχνητή νοημοσύνη έχει συμβάλει ουσιαστικά στη βελτίωση τριών βασικών χαρακτηριστικών των σύγχρονων recommender systems: της ακρίβειας, της προσαρμοστικότητας και της λειτουργικότητάς τους. Η ενσωμάτωση τεχνικών μηχανικής μάθησης (machine learning) και βαθιάς μάθησης (deep learning) έχει μετασχηματίσει τα RS από απλά στατιστικά μοντέλα σε πιο σύνθετα και ευφυή συστήματα, ικανά να επεξεργάζονται μεγάλους όγκους δεδομένων και να εντοπίζουν πολύπλοκα πρότυπα συμπεριφοράς. Η επίδραση της AI στις επιχειρήσεις μπορεί να γίνει κατανοητή μέσα από τρία επίπεδα εφαρμογής: τη Μηχανική ΤΝ (Mechanical AI) που αυτοματοποιεί επαναλαμβανόμενες εργασίες, τη Σκεπτόμενη ΤΝ (Thinking AI) που αναλύει δεδομένα για εξατομίκευση και στόχευση, και τη Συναισθηματική ΤΝ (Feeling AI) που προσομοιώνει την ανθρώπινη αλληλεπίδραση για τη δημιουργία δεσμού και εμπιστοσύνης με τον πελάτη (Huang & Rust, 2018). Τα συστήματα συστάσεων κινούνται κυρίως στο δεύτερο επίπεδο, αν και ολοένα και περισσότερο ενσωματώνουν στοιχεία από το τρίτο. Χάρη στην αξιοποίηση της AI, τα συστήματα συστάσεων αποκτούν μεγαλύτερη ευελιξία και μπορούν να προσαρμόζονται δυναμικά στις μεταβαλλόμενες προτιμήσεις των χρηστών. Είναι χρήσιμο να διευκρινιστεί εξαρχής η σχέση των δύο αυτών πεδίων: η Μηχανική Μάθηση (Machine Learning – ML) αποτελεί υποσύνολο της Τεχνητής Νοημοσύνης (Artificial Intelligence – AI), και τα συστήματα συστάσεων θεωρούνται ένα από τα πιο επιτυχημένα πεδία εφαρμογής τους (Alamdari et al., 2020). Σύμφωνα με τους Alamdari et al. (2020), η ανάλυση ιστορικών δεδομένων και η συνεχής εκπαίδευση των μοντέλων επιτρέπουν στα συστήματα να προβλέπουν με μεγαλύτερη ακρίβεια τις μελλοντικές επιλογές των χρηστών. Με αυτόν τον τρόπο, βελτιώνεται η ποιότητα των προτάσεων και ενισχύεται συνολικά η εμπειρία χρήστη. Ιδιαίτερα σημαντική είναι η συμβολή των τεχνικών βαθιάς μάθησης (deep learning). Οι τεχνικές αυτές επιτρέπουν την εξαγωγή αναπαραστάσεων υψηλού επιπέδου (embeddings) από δεδομένα μεγάλης πολυπλοκότητας, όπως κείμενο, εικόνα, ήχο και αλληλεπιδράσεις

χρηστών. Όπως αναφέρουν οι Gao et al. (2023), τα μοντέλα deep learning έχουν τη δυνατότητα να εντοπίζουν μη γραμμικές σχέσεις, κρυφά μοτίβα και λανθάνουσες συσχετίσεις, οι οποίες δεν είναι εύκολο να ανιχνευθούν με πιο παραδοσιακές μεθόδους. Το αποτέλεσμα είναι η παραγωγή ακριβέστερων και περισσότερο εξατομικευμένων συστάσεων. Παράλληλα, η ανάπτυξη των Graph Neural Networks (GNNs) έχει προσφέρει νέες δυνατότητες στην ανάλυση των σχέσεων μεταξύ χρηστών και αντικειμένων (Gao et al., 2023). Πρόκειται για νευρωνικά δίκτυα που, αντί να βλέπουν τα δεδομένα ως ανεξάρτητες εγγραφές, τα οργανώνουν σε κόμβους και ακμές, δηλαδή σε έναν γράφο. Έτσι, μπορούν να «διαβάσουν» όχι μόνο τι έκανε ένας χρήστης, αλλά και πώς αυτό συνδέεται με άλλους χρήστες ή προϊόντα. Η τεχνική αυτή είναι ιδιαίτερα αποτελεσματική σε περιβάλλοντα όπου τα δεδομένα παρουσιάζουν υψηλό βαθμό διασύνδεσης, όπως τα κοινωνικά δίκτυα και οι πλατφόρμες ηλεκτρονικού εμπορίου. Μέσα από τη χρήση γράφων, τα συστήματα μπορούν να αξιοποιούν όχι μόνο τις άμεσες σχέσεις μεταξύ χρήστη και αντικειμένου, αλλά και πιο σύνθετες ή έμμεσες συνδέσεις, βελτιώνοντας έτσι την ακρίβεια και τη συνάφεια των προτάσεων. Επιπλέον, η τεχνητή νοημοσύνη συμβάλλει στην ανάπτυξη των context-aware recommender systems, δηλαδή συστημάτων συστάσεων που λαμβάνουν υπόψη το πλαίσιο χρήσης (context). Στα συστήματα αυτά, παράμετροι όπως ο χρόνος, η τοποθεσία και η τρέχουσα δραστηριότητα του χρήστη ενσωματώνονται στη διαδικασία παραγωγής προτάσεων. Για παράδειγμα, συστήματα όπως το SMARTBUY δεν λαμβάνουν υπόψη μόνο την τρέχουσα θέση του χρήστη, αλλά και το ιστορικό τοποθεσίας του, ώστε να προτείνουν προϊόντα σε περιοχές που επισκέπτεται συχνά, ακόμα κι αν βρίσκονται μακριά από εκείνη τη στιγμή (Mateos & Bellogín, 2025) Έτσι, οι ανάγκες ενός χρήστη μπορεί να διαφέρουν ανάλογα με το αν βρίσκεται στο σπίτι, στο γραφείο ή σε ταξίδι, καθώς και ανάλογα με την ώρα της ημέρας.

Η αξιοποίηση τέτοιων παραμέτρων επιτρέπει την παραγωγή πιο σχετικών και χρονικά κατάλληλων προτάσεων, καθώς το σύστημα δεν βασίζεται μόνο στο ιστορικό του χρήστη, αλλά και στις συνθήκες μέσα στις οποίες πραγματοποιείται η αλληλεπίδραση (Adomavicius & Tuzhilin, 2005).

Παρά τα σημαντικά πλεονεκτήματα, η εφαρμογή της τεχνητής νοημοσύνης στα συστήματα συστάσεων συνοδεύεται και από ορισμένες προκλήσεις. Όπως επισημαίνουν οι Gao et al. (2023), οι προκλήσεις αυτές περιλαμβάνουν την αυξημένη υπολογιστική πολυπλοκότητα (computational complexity), την ανάγκη για μεγάλα και ποιοτικά σύνολα δεδομένων, καθώς

και ζητήματα ερμηνευσιμότητας (interpretability). Αρχικά, τα μοντέλα βαθιάς μάθησης απαιτούν σημαντικούς υπολογιστικούς πόρους, όπως ισχυρούς servers και GPUs, ενώ η αποτελεσματικότητά τους εξαρτάται σε μεγάλο βαθμό από τη διαθεσιμότητα επαρκών και αξιόπιστων δεδομένων. Έπειτα, τα πιο σύνθετα μοντέλα λειτουργούν συχνά ως «μαύρα κουτιά», γεγονός που δυσκολεύει την κατανόηση του τρόπου με τον οποίο παράγεται μια συγκεκριμένη πρόταση. Ακόμα, η ερμηνευσιμότητα αποτελεί κρίσιμο ζήτημα, ιδιαίτερα σε τομείς όπου απαιτούνται διαφάνεια και λογοδοσία, όπως οι χρηματοοικονομικές υπηρεσίες και η υγεία. Σε τέτοια περιβάλλοντα, δεν αρκεί το σύστημα να παρέχει ακριβείς προτάσεις, είναι εξίσου σημαντικό να μπορεί να εξηγήσει, έστω σε κάποιο βαθμό, τη λογική πίσω από αυτές.

Γίνεται, επομένως, εύκολα αντιληπτό, πως η τεχνητή νοημοσύνη αποτελεί βασικό μοχλό εξέλιξης των συστημάτων συστάσεων. Επιτρέπει την ανάπτυξη πιο advanced, precise, και adaptable μοντέλων, τα οποία μπορούν να ανταποκρίνονται καλύτερα στις ανάγκες των χρηστών και στις απαιτήσεις του σύγχρονου ψηφιακού περιβάλλοντος. Ταυτόχρονα, όμως, η αξιοποίησή της αναδεικνύει νέες προκλήσεις, κυρίως σε επίπεδο υπολογιστικών απαιτήσεων, ποιότητας δεδομένων και ερμηνευσιμότητας. Η συνεχής πρόοδος στον τομέα της AI αναμένεται να ενισχύσει ακόμη περισσότερο τις δυνατότητες των recommender systems, καθιστώντας τα ολοένα πιο αποτελεσματικά και αναγκαία στο σύγχρονο ψηφιακό οικοσύστημα.

4.2. Απλές Τεχνικές Μηχανικής Μάθησης

Η εφαρμογή τεχνικών μηχανικής μάθησης στα συστήματα συστάσεων έχει συμβάλει σημαντικά στη βελτίωση της ακρίβειας και της αποδοτικότητάς τους. Όπως επισημαίνουν οι Alamdari et al. (2020) και οι Gao et al. (2023), οι τεχνικές αυτές επιτρέπουν την ανάλυση μεγάλων συνόλων δεδομένων, την αναγνώριση προτύπων και την πρόβλεψη των προτιμήσεων των χρηστών με μεγαλύτερη αποτελεσματικότητα. Μεταξύ των πιο διαδεδομένων προσεγγίσεων περιλαμβάνονται η παραγοντοποίηση μητρώων (matrix factorization), οι μέθοδοι ομαδοποίησης (clustering) και οι τεχνικές βαθιάς μάθησης (deep learning).

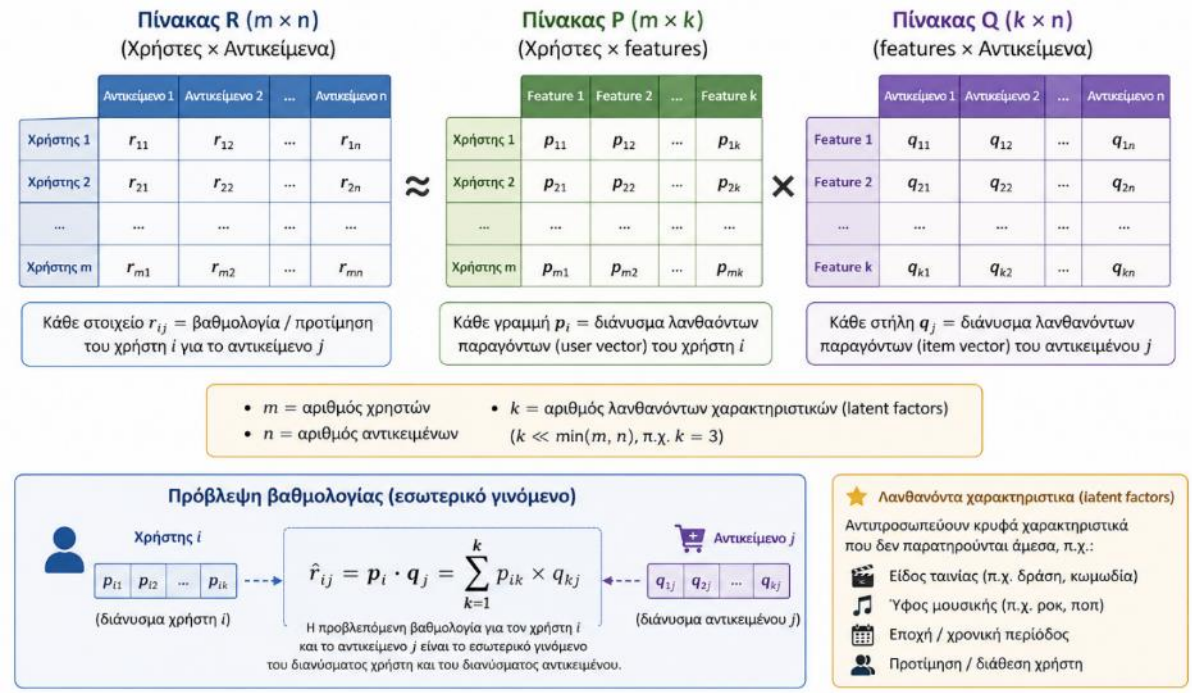
4.2.1. Matrix Factorization

Η παραγοντοποίηση μητρώων (matrix factorization) αποτελεί μία από τις σημαντικότερες και πιο ευρέως χρησιμοποιούμενες τεχνικές στα recommender systems, ιδιαίτερα στο πλαίσιο του collaborative filtering. Σύμφωνα με τους Koren et al. (2009), η βασική λογική της μεθόδου είναι η αποσύνθεση του πίνακα αλληλεπιδράσεων χρηστών - αντικειμένων σε δύο πίνακες χαμηλότερης διάστασης. Ο πίνακας P αναπαριστά τους χρήστες ως προς k λανθάνοντα χαρακτηριστικά, και ο Q τα αντικείμενα..

Πιο συγκεκριμένα, κάθε χρήστης και κάθε αντικείμενο αναπαρίσταται ως διάνυσμα μέσα σε έναν κοινό λανθάνοντα χώρο χαρακτηριστικών. Η πρόβλεψη της προτίμησης ενός χρήστη για ένα συγκεκριμένο αντικείμενο προκύπτει από το εσωτερικό γινόμενο των αντίστοιχων διανυσμάτων. Με αυτόν τον τρόπο, η μέθοδος μπορεί να εντοπίζει κρυφές σχέσεις και συσχετίσεις, οι οποίες δεν είναι άμεσα ορατές στα αρχικά δεδομένα.

Το matrix factorization παρουσιάζει σημαντικά πλεονεκτήματα, καθώς μπορεί να αντιμετωπίσει σε μεγάλο βαθμό το πρόβλημα της αραιότητας των δεδομένων και να εφαρμοστεί αποτελεσματικά σε μεγάλα σύνολα δεδομένων. Ωστόσο, η μέθοδος απαιτεί επαρκή ποσότητα δεδομένων για την εκπαίδευση των μοντέλων και παρουσιάζει περιορισμένη ερμηνευσιμότητα, καθώς οι λανθάνουσες παράμετροι που παράγονται δεν είναι πάντοτε εύκολο να ερμηνευθούν με σαφή τρόπο (Alamdari et al., 2020). Στην πράξη, αλγόριθμοι όπως ο SVD (Singular Value Decomposition) έχουν αναδειχθεί σε ιδιαίτερα αποδοτικές επιλογές για περιβάλλοντα ηλεκτρονικού εμπορίου, συχνά επιτυγχάνοντας τα χαμηλότερα σφάλματα πρόβλεψης (Koren, Bell & Volinsky, 2009). Υλοποιήσεις τους είναι διαθέσιμες μέσω βιβλιοθηκών όπως η Surprise της Python, καθιστώντας τες προσιτές και σε μικρότερους οργανισμούς.

Η οπτικοποίηση της μεθόδου παρουσιάζεται στο Σχεδιάγραμμα 4.1.



Σχεδιάγραμμα 4. 1

Παραγοντοποίηση μητρώου (Matrix Factorization). Ο αρχικός πίνακας αλληλεπιδράσεων R (διαστάσεων m × n) προσεγγίζεται από το γινόμενο δύο χαμηλότερης διάστασης πινάκων P (διαστάσεων m × k) και Q (διαστάσεων k × n), όπου k είναι ο αριθμός των λανθανόντων χαρακτηριστικών (latent factors). ***Προσαρμογή από Koren et al. (2009).***

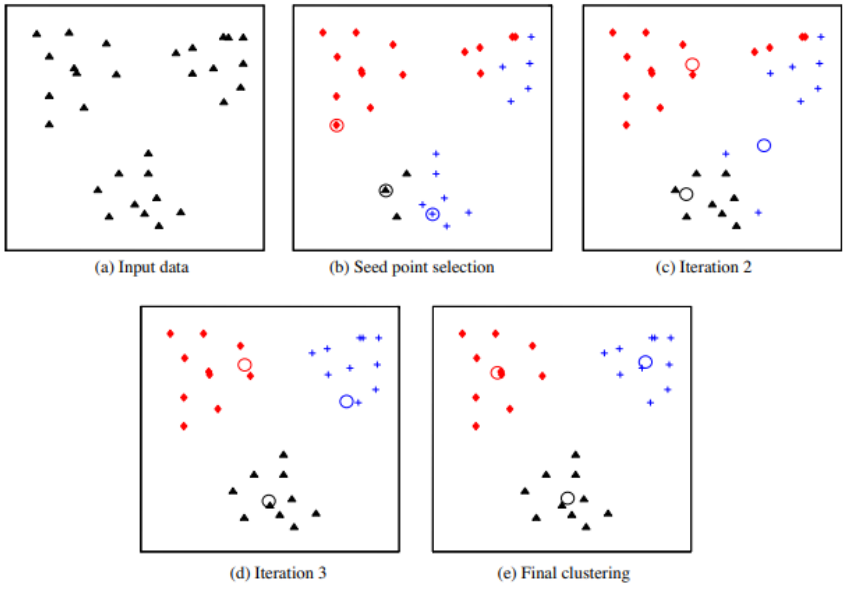
4.2.2. Clustering (K-Means)

Οι μέθοδοι ομαδοποίησης (clustering) χρησιμοποιούνται στα συστήματα συστάσεων για την κατηγοριοποίηση χρηστών ή αντικειμένων σε ομάδες που παρουσιάζουν κοινά ή παρόμοια χαρακτηριστικά. Όπως εξηγεί ο Jain (2010), ο αλγόριθμος k-means αποτελεί μία από τις πιο γνωστές και ευρέως χρησιμοποιούμενες τεχνικές ομαδοποίησης. Η βασική του λειτουργία είναι ο διαχωρισμός των δεδομένων σε k ομάδες, με στόχο τα στοιχεία που ανήκουν στην ίδια ομάδα να παρουσιάζουν όσο το δυνατόν μεγαλύτερη ομοιότητα μεταξύ τους, ενώ τα στοιχεία διαφορετικών ομάδων να διαφέρουν όσο περισσότερο γίνεται.

Στο πλαίσιο των recommender systems, το clustering μπορεί να εφαρμοστεί είτε για τη δημιουργία ομάδων χρηστών με παρόμοια πρότυπα συμπεριφοράς είτε για την ομαδοποίηση αντικειμένων που διαθέτουν κοινά χαρακτηριστικά. Για παράδειγμα, χρήστες με παρόμοιο ιστορικό αγορών, αξιολογήσεων ή πλοήγησης μπορούν να ενταχθούν στην ίδια ομάδα, ώστε το σύστημα να αξιοποιήσει τα κοινά τους χαρακτηριστικά για την παραγωγή προτάσεων.

Οι συστάσεις παράγονται με βάση τις ιδιότητες και τη συμπεριφορά της ομάδας στην οποία ανήκει ο χρήστης ή το αντικείμενο. Με τον τρόπο αυτό, μειώνεται η υπολογιστική πολυπλοκότητα, καθώς το σύστημα δεν χρειάζεται να συγκρίνει κάθε χρήστη ή αντικείμενο με όλα τα υπόλοιπα, αλλά μπορεί να βασιστεί στις ομάδες που έχουν ήδη διαμορφωθεί. Αυτό επιτρέπει την ταχύτερη παραγωγή προτάσεων και καθιστά τη μέθοδο ιδιαίτερα χρήσιμη σε εφαρμογές με μεγάλο όγκο δεδομένων.

Μολαταύτα, η μέθοδος παρουσιάζει και ορισμένους περιορισμούς. Η ποιότητα των αποτελεσμάτων εξαρτάται σε μεγάλο βαθμό από την επιλογή του k, δηλαδή του αριθμού των ομάδων που θα δημιουργηθούν. Λόγου χάρη, σε μια εφαρμογή ομαδοποίησης χρηστών με βάση τις αγοραστικές τους συνήθειες, ένα πολύ μικρό k μπορεί να συγχωνεύσει διακριτές ομάδες καταναλωτών σε μία, χάνοντας σημαντικές διαφοροποιήσεις, ενώ ένα υπερβολικά μεγάλο k μπορεί να κατακερματίσει ομάδες που στην πραγματικότητα παρουσιάζουν κοινή συμπεριφορά, δημιουργώντας ψευδείς διαχωρισμούς (Jain, 2010). Επιπλέον, το k-means ενδέχεται να μην αποτυπώνει με ακρίβεια πιο σύνθετες ή δυναμικές προτιμήσεις, Ο αλγόριθμος υποθέτει ότι οι ομάδες είναι σφαιρικές και έχουν παρόμοια πυκνότητα, γεγονός που σπάνια ισχύει σε πραγματικά δεδομένα καταναλωτικής συμπεριφοράς (Jain, 2010). Όπως είδαμε και σε προηγούμενο παράδειγμα, χρήστες που αλλάζουν ενδιαφέροντα ανάλογα με την εποχή ή την ώρα της ημέρας ενδέχεται να ανήκουν σε διαφορετικές «ομάδες» ανάλογα με το πλαίσιο, κάτι που μια στατική ομαδοποίηση αδυνατεί να παρακολουθήσει (Alamdari et al., 2020). Αυτός είναι και ο λόγος που η εν λόγω τεχνική είναι πολύτιμη σε εφαρμογές μεγάλης κλίμακας" θα έδενε το επιχείρημα. Η λειτουργία του αλγορίθμου απεικονίζεται στο Σχεδιάγραμμα 4.2.



Σχεδιάγραμμα 4. 2

Οπτικοποίηση του αλγορίθμου k-means. (α) Αρχικά δεδομένα με τρεις ομάδες. (β) Επιλογή αρχικών κέντρων (seed points) και αρχική αντιστοίχιση σημείων. (γ) και (δ) Ενδιάμεσες επαναλήψεις – ενημέρωση ομάδων και κέντρων. (ε) Τελική ομαδοποίηση μετά από σύγκλιση του αλγορίθμου. *Πηγή: Jain (2010).*

4.2.3. Βασικά Στοιχεία Deep Learning

Οι τεχνικές βαθιάς μάθησης (deep learning) έχουν ιδιαίτερη σημασία για την εξέλιξη των συστημάτων συστάσεων, καθώς επιτρέπουν την επεξεργασία σύνθετων δεδομένων. Σύμφωνα με τους Gao et al. (2023), ένα από τα βασικά στοιχεία αυτών των τεχνικών είναι τα embeddings, δηλαδή οι διανυσματικές αναπαραστάσεις χρηστών και αντικειμένων σε έναν χώρο χαμηλότερης διάστασης.

Τα embeddings επιτρέπουν την αποτύπωση σημασιολογικών σχέσεων μεταξύ των δεδομένων και βοηθούν το σύστημα να εντοπίζει ομοιότητες, μοτίβα και συσχετίσεις που δεν είναι άμεσα εμφανή στα αρχικά δεδομένα (Mikolov et al., 2013). Για παράδειγμα, σε ένα σύστημα συστάσεων ταινιών, τα embeddings μπορούν να αποτυπώσουν σχέσεις μεταξύ διαφορετικών ειδών, θεματικών ή προτιμήσεων των χρηστών, ακόμη και όταν αυτές οι σχέσεις δεν έχουν δηλωθεί ρητά. Η χρήση τεχνικών βαθιάς μάθησης προσφέρει σημαντικά πλεονεκτήματα. Επιτρέπει την ενσωμάτωση πολλαπλών τύπων δεδομένων, όπως κείμενο, εικόνα και ήχο, οδηγώντας σε μια πιο ολιστική κατανόηση των προτιμήσεων των χρηστών (Zhang et al., 2019). Ακόμα, υποστηρίζει τη δημιουργία πιο δυναμικών και προσαρμοστικών συστημάτων,

τα οποία ανταποκρίνονται καλύτερα στις μεταβαλλόμενες ανάγκες και παράγουν ακριβέστερες, πιο εξατομικευμένες προτάσεις

Ωστόσο, και σε αυτή την περίπτωση εξακολουθούν να ισχύουν οι ίδιοι περιοριστικοί παράγοντες που αναφέρθηκαν στην ενότητα 4.1, κυρίως η ανάγκη για αυξημένους υπολογιστικούς πόρους και μεγάλα σύνολα δεδομένων, καθώς και τα ζητήματα ερμηνευσιμότητας που προκύπτουν από τη λειτουργία των μοντέλων ως «μαύρα κουτιά» (Gao et al., 2023).

Ανακεφαλαιώνοντας, οι τεχνικές μηχανικής μάθησης αποτελούν βασικό εργαλείο για την ανάπτυξη αποδοτικών και σύγχρονων συστημάτων συστάσεων. Η επιλογή της κατάλληλης μεθόδου εξαρτάται από τα διαθέσιμα δεδομένα, τις απαιτήσεις της εφαρμογής και τους επιχειρησιακούς στόχους. Σε πολλές περιπτώσεις, η βέλτιστη απόδοση επιτυγχάνεται μέσα από τον συνδυασμό πολλαπλών τεχνικών, ώστε το σύστημα να αξιοποιεί τα πλεονεκτήματα κάθε προσέγγισης και να παράγει πιο αξιόπιστες και χρήσιμες συστάσεις.

4.3.Ενίσχυση Αλγορίθμων μέσω Τεχνητής Νοημοσύνης

Η ενσωμάτωση τεχνικών τεχνητής νοημοσύνης έχει αναβαθμίσει σημαντικά τους παραδοσιακούς αλγορίθμους συστάσεων. Ενώ οι πρώτες προσεγγίσεις βασίζονταν κυρίως σε απλές στατιστικές μεθόδους και ευρετικές τεχνικές, η σύγχρονη αξιοποίηση της AI επιτρέπει τη μοντελοποίηση πιο σύνθετων σχέσεων και τη διαχείριση μεγάλου όγκου ετερογενών δεδομένων (Ricci et al., 2010, Gao et al., 2023).

Δεν υπάρχει αμφιβολία πως μία από τις βασικές συνεισφορές της τεχνητής νοημοσύνης είναι η ενίσχυση της προβλεπτικής ικανότητας των recommender systems. Όπως επισημαίνουν οι Alamdari et al. (2020), μέσω προηγμένων αλγορίθμων μηχανικής μάθησης και βαθιάς μάθησης, τα μοντέλα μπορούν να εντοπίζουν μη γραμμικές σχέσεις μεταξύ χρηστών και αντικειμένων, οι οποίες δεν μπορούν πάντα να αποτυπωθούν με τις παραδοσιακές μεθόδους collaborative filtering.

Η δυνατότητα αυτή οδηγεί σε σημαντική βελτίωση της ακρίβειας των προτάσεων, καθώς το σύστημα μπορεί να κατανοεί πιο σύνθετα μοτίβα συμπεριφοράς και να προσαρμόζεται καλύτερα στις μεταβαλλόμενες προτιμήσεις των χρηστών.

Η AI επιτρέπει, επίσης, την συγχώνευση πολλαπλών πηγών δεδομένων σε ένα ενιαίο μοντέλο. Σύμφωνα με τους Adomavicius και Tuzhilin (2005), πέρα από τα κλασικά δεδομένα αλληλεπίδρασης, όπως αξιολογήσεις, clicks και ιστορικό αγορών, μπορούν να αξιοποιηθούν και άλλες μορφές πληροφορίας. Αυτές περιλαμβάνουν δεδομένα περιεχομένου, όπως περιγραφές προϊόντων, δημογραφικά χαρακτηριστικά, δεδομένα κοινωνικών δικτύων, καθώς και συμφραζόμενα στοιχεία (contextual data), όπως η τοποθεσία, η ώρα και η συσκευή που χρησιμοποιεί ο χρήστης. Η πολυδιάστατη αυτή προσέγγιση επιτρέπει τη δημιουργία πιο ολοκληρωμένων προφίλ χρηστών και οδηγεί σε προτάσεις που είναι περισσότερο σχετικές με τις πραγματικές ανάγκες και τις συνθήκες χρήσης.

Στη συνέχεια, θα αποτελούσε σοβαρή παράλειψη να μην τονίσουμε το πρόβλημα της ψυχρής εκκίνησης (cold start), που αναλύθηκε στην ενότητα 2.4. Βάσει αυτού, υπάρχει αδυναμία όταν το σύστημα καλείται να παράγει συστάσεις για νέους χρήστες ή νέα αντικείμενα χωρίς επαρκή ιστορικά δεδομένα. Οι Gao et al. (2023) προτείνουν την αξιοποίηση πλευρικών πληροφοριών (side information), όπως δημογραφικά χαρακτηριστικά και μεταδεδομένα περιεχομένου, ως κύρια στρατηγική αντιμετώπισης.

Αξίζει, επιπλέον, να αναφερθούμε στο γεγονός πως η AI υποστηρίζει την ανάπτυξη πιο προσαρμοστικών και δυναμικών RS. Τα σύγχρονα μοντέλα μπορούν να ενημερώνονται σε πραγματικό χρόνο (real-time), αξιοποιώντας νέες αλληλεπιδράσεις, αλλαγές στη συμπεριφορά των χρηστών και εποχικές ή χρονικές τάσεις, μια ικανότητα που βασίζεται σε τεχνικές online μάθησης (Mairal et al., 2010, Li et al., 2023) Η δυνατότητα αυτή είναι ιδιαίτερα σημαντική σε εφαρμογές όπου η επικαιρότητα των προτάσεων παίζει κρίσιμο ρόλο, όπως οι πλατφόρμες ηλεκτρονικού εμπορίου, τα συστήματα streaming, οι ειδησεογραφικές υπηρεσίες και οι πλατφόρμες βίντεο. Σε τέτοια περιβάλλοντα, οι προτιμήσεις των χρηστών μπορεί να μεταβάλλονται γρήγορα, επομένως το σύστημα πρέπει να μπορεί να προσαρμόζεται άμεσα.

Ωστόσο, η ενίσχυση των αλγορίθμων μέσω τεχνητής νοημοσύνης συνοδεύεται και από σημαντικές προκλήσεις. Πολλές από αυτές, όπως η δυσκολία ερμηνείας των σύνθετων μοντέλων, οι υψηλές απαιτήσεις σε υπολογιστικούς πόρους και η ανάγκη για μεγάλα, ποιοτικά σύνολα δεδομένων, σημεία που έχουν ήδη αναλυθεί στις προηγούμενες ενότητες (βλ. 4.1 και 4.2.3) και παραμένουν κεντρικά εμπόδια, ιδίως για οργανισμούς με περιορισμένες τεχνολογικές υποδομές (Gao et al., 2023)..

Ανακεφαλαιώνοντας, συμπεραίνουμε πως η τεχνητή νοημοσύνη αποτελεί καθοριστικό παράγοντα εξέλιξης των recommender systems. Ενισχύει τις δυνατότητες των αλγορίθμων σε πέντε βασικούς άξονες: την πρόβλεψη, την ενοποίηση δεδομένων, την αντιμετώπιση της αραιότητας, την ενημέρωση σε πραγματικό χρόνο και την προσαρμοστικότητα.

Παρά τις προκλήσεις που σχετίζονται με την πολυπλοκότητα, την ανάγκη για ποιοτικά δεδομένα και την ερμηνευσιμότητα, η συνεχής πρόοδος στον τομέα της AI αναμένεται να οδηγήσει σε ακόμη πιο αποτελεσματικά συστήματα συστάσεων. Έτσι, τα RS καθίστανται ολοένα πιο ακριβή, πιο προσαρμοστικά και περισσότερο χρήσιμα για τις σύγχρονες επιχειρήσεις που δραστηριοποιούνται στο ψηφιακό περιβάλλον.

4.4.Παραδείγματα Εργαλείων Recommender Systems

Η ανάπτυξη και η εφαρμογή συστημάτων συστάσεων έχει ενισχυθεί σημαντικά από τη διαθεσιμότητα εξειδικευμένων εργαλείων και πλατφορμών. Όπως επισημαίνουν οι Gao et al. (2023), τα εργαλεία αυτά δίνουν τη δυνατότητα στις επιχειρήσεις να υλοποιούν, να παραμετροποιούν και να βελτιστοποιούν αλγορίθμους προτάσεων, χωρίς να απαιτείται πάντοτε εκτεταμένη τεχνική εξειδίκευση. Παράλληλα, ενσωματώνουν σύγχρονες τεχνικές μηχανικής μάθησης και τεχνητής νοημοσύνης, προσφέροντας έτοιμες ή ημ-έτοιμες λύσεις για την ανάπτυξη αποδοτικών recommender systems. Παρακάτω βλέπουμε κάποια από αυτά τα ερργαλεία.

1. Amazon Personalize: Το Amazon Personalize αποτελεί μια πλήρως διαχειριζόμενη υπηρεσία μηχανικής μάθησης της Amazon Web Services, σχεδιασμένη για την ανάπτυξη εξατομικευμένων RS. Η υπηρεσία επιτρέπει στους χρήστες να παρέχουν τα δεδομένα αλληλεπίδρασής τους (π.χ. προβολές, αγορές, αξιολογήσεις), αναλαμβάνοντας αυτόματα την επιλογή του κατάλληλου αλγορίθμου, την εκπαίδευση του μοντέλου και την παραγωγή προτάσεων σε πραγματικό χρόνο μέσω απλών API (Amazon Web Services, 2023). Πρόκειται ουσιαστικά για μια λύση που παρέχει πρόσβαση σε προηγμένες τεχνικές συστάσεων, κάνοντας τες προσιτές ακόμη και σε επιχειρήσεις χωρίς εξειδικευμένο προσωπικό data scientists. Ένα ιδιαίτερα χρήσιμο χαρακτηριστικό της είναι η δυνατότητα εφαρμογής επιχειρηματικών κανόνων (business rules) στις παραγόμενες προτάσεις. Λόγου χάρη, ο

αποκλεισμός προϊόντων εκτός αποθέματος ή η προώθηση συγκεκριμένων κατηγοριών στη διάρκεια μιας καμπάνιας marketing.

2. EasyRec: Το EasyRec είναι ένα framework ανοικτού κώδικα που αναπτύχθηκε από την Alibaba για τη δημιουργία βιομηχανικών συστημάτων συστάσεων (Cheng et al., 2022). Σε αντίθεση με τις έτοιμες υπηρεσίες cloud, το EasyRec προσφέρει μεγαλύτερη ευελιξία στους προγραμματιστές, επιτρέποντάς τους να συνθέσουν το δικό τους μοντέλο επιλέγοντας έτοιμα δομικά στοιχεία (modular σχεδιασμός). Αυτό σημαίνει ότι αντί να χτίζουν έναν αλγόριθμο από το μηδέν, μπορούν να συνδυάσουν διαφορετικά «κομμάτια» (π.χ. ένα επίπεδο εξαγωγής χαρακτηριστικών με έναν ταξινομητή), μειώνοντας σημαντικά τον χρόνο ανάπτυξης. Επιπλέον, ενσωματώνει μηχανισμούς αυτόματης βελτιστοποίησης υπερπαραμέτρων (auto-tuning), δηλαδή ρυθμίζει μόνο του κρίσιμες παραμέτρους που θα χρειαζόταν διαφορετικά να δοκιμάσει χειροκίνητα ένας ειδικός. Τέλος, υποστηρίζει online learning, επιτρέποντας στο μοντέλο να ενημερώνεται συνεχώς καθώς καταφθάνουν νέα δεδομένα, χωρίς να απαιτείται επανεκπαίδευση από την αρχή.

Εκτός από τα παραπάνω, στη βιβλιογραφία και στην πράξη συναντώνται και άλλες πλατφόρμες που χρησιμοποιούνται για την ανάπτυξη, την αξιολόγηση ή την πειραματική εφαρμογή συστημάτων συστάσεων (Monti, Rizzo & Morisio, 2017). Ενδεικτικά, το Apache Mahout αποτελεί εργαλείο ανοικτού κώδικα με έμφαση στην κλιμάκωση και στην επεξεργασία μεγάλων δεδομένων, και έχει χρησιμοποιηθεί εμπορικά από εταιρείες όπως η Amazon, η Yahoo! και το Foursquare για συστήματα προτάσεων και ανάλυση δεδομένων (Owen et al., 2011). Το LensKit χρησιμοποιείται κυρίως για ερευνητικούς σκοπούς και για την αξιολόγηση αλγορίθμων συστάσεων, όντας ένα από τα πιο διαδεδομένα εργαλεία στην ακαδημαϊκή κοινότητα (Monti, Rizzo & Morisio, 2017). Επιπλέον, εργαλεία όπως το LibRec και το CARSKit έχουν χρησιμοποιηθεί για διαφορετικές ερευνητικές ανάγκες, όπως η ανάπτυξη context-aware συστημάτων και η υποστήριξη πολλαπλών αλγορίθμων.

Η αξιοποίηση των παραπάνω εργαλείων δείχνει τη μετάβαση των recommender systems από το επίπεδο της θεωρητικής ανάλυσης στο επίπεδο της πρακτικής εφαρμογής. Οι επιχειρήσεις έχουν πλέον τη δυνατότητα είτε να επιλέξουν έτοιμες λύσεις τύπου SaaS, δηλαδή υπηρεσίες που φιλοξενούνται στο cloud και χρησιμοποιούνται μέσω διαδικτύου χωρίς να απαιτείται εγκατάσταση ή συντήρηση από τον χρήστη, είτε να προσαρμόσουν ανοικτά εργαλεία στις δικές τους ανάγκες. Με αυτόν τον τρόπο, μπορούν να επιτύχουν ταχύτερη υλοποίηση, χαμηλότερο κόστος ανάπτυξης και καλύτερη απόδοση των συστημάτων τους.

Συνοψίζοντας, τα εργαλεία recommender systems, όπως το Amazon Personalize και το EasyRec, παίζουν σημαντικό ρόλο στη μετάβαση από τη θεωρία στην πράξη. Επιτρέπουν την ανάπτυξη αποδοτικών συστημάτων, μειώνοντας σημαντικά τον χρόνο υλοποίησης και, σε πολλές περιπτώσεις, το απαιτούμενο κόστος υποδομής και εξειδίκευσης (Cheng et al., 2022, Amazon Web Services, 2023)

4.5. Μελλοντικές Εξελίξεις (LLMs, Conversational Recommender Systems)

Οι πρόσφατες εξελίξεις στην τεχνητή νοημοσύνη διαμορφώνουν σταδιακά μια νέα γενιά συστημάτων συστάσεων, όπου η έμφαση μετατοπίζεται από την απλή πρόβλεψη προτιμήσεων σε πιο ευέλικτες, διαδραστικές και σημασιολογικά πλούσιες μορφές εξατομίκευσης. Δύο τεχνολογίες διαδραματίζουν κεντρικό ρόλο σε αυτή τη μετάβαση: τα μεγάλα γλωσσικά μοντέλα (Large Language Models - LLMs) και τα συνομιλιακά συστήματα συστάσεων (Conversational Recommender Systems - CRS) (Gao et al., 2023). Η σημασία αυτών των τεχνολογιών για τις επιχειρήσεις δεν είναι απλώς τεχνολογική, αλλά βαθιά στρατηγική. Τα GNNs επιτρέπουν σε μια πλατφόρμα να κατανοήσει όχι μόνο τι αρέσει σε έναν χρήστη, αλλά και πώς οι προτιμήσεις του συνδέονται με εκείνες άλλων χρηστών, δημιουργώντας έναν δυναμικό «χάρτη» σχέσεων που βελτιώνει δραματικά την ακρίβεια των προτάσεων. Για μια επιχείρηση ηλεκτρονικού εμπορίου, αυτό μεταφράζεται σε υψηλότερα conversion rates και μεγαλύτερο μέσο καλάθι. Τα LLMs, από την άλλη, μετασχηματίζουν την ίδια τη φύση της αλληλεπίδρασης: ο πελάτης δεν ψάχνει πλέον προϊόντα, αλλά συνομιλεί με την πλατφόρμα, εκφράζοντας ανάγκες σε φυσική γλώσσα. Αυτή η μετάβαση από την αναζήτηση στον διάλογο μειώνει την τριβή, αυξάνει την ικανοποίηση και, τελικά, ενισχύει την αφοσίωση του πελάτη (Fan et al., 2023).

Και στις δύο περιπτώσεις, η επιχειρησιακή αξία δεν προκύπτει από την τεχνολογία καθεαυτή, αλλά από το πώς αυτή ευθυγραμμίζεται με τον στρατηγικό στόχο της πλατφόρμας. Το Netflix, για παράδειγμα, δεν επενδύει σε GNNs επειδή είναι «μοντέρνα», αλλά επειδή η ικανότητα μοντελοποίησης σύνθετων σχέσεων μεταξύ χρηστών και περιεχομένου είναι αυτό που κρατά τον συνδρομητή στην οθόνη του. Αντίστοιχα, η ενσωμάτωση LLMs σε μια πλατφόρμα όπως το Tripadvisor θα μπορούσε να μετατρέψει τον σχεδιασμό ενός ταξιδιού

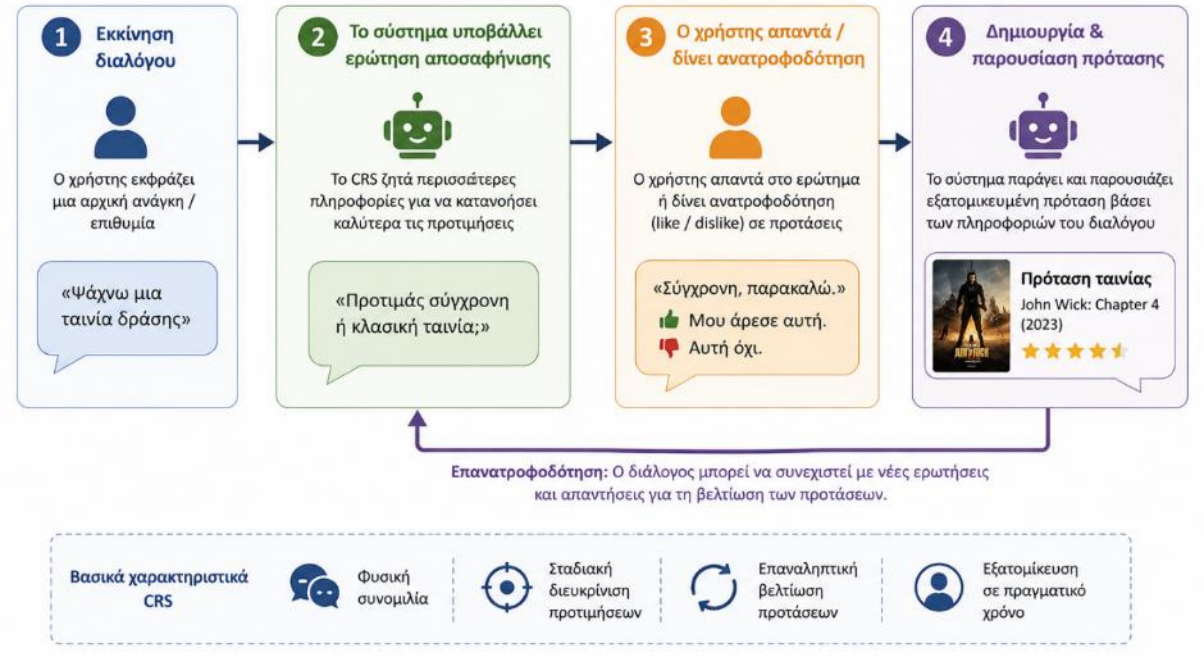
από μια χρονοβόρα διαδικασία σύγκρισης σε μια σύντομη, φυσική συνομιλία, μειώνοντας την εγκατάλειψη και αυξάνοντας τις κρατήσεις (Jannach & Jugovac, 2019).

Κατ' αρχάς, τα LLMs επιτρέπουν την κατανόηση και επεξεργασία της φυσικής γλώσσας σε ένα πρωτόγνωρο επίπεδο σημασιολογικής ανάλυσης (Brown et al., 2020, Devlin et al., 2018). Χαρακτηριστικά παραδείγματα αποτελούν το GPT (Generative Pre-trained Transformer) της OpenAI, που εξειδικεύεται στην παραγωγή κειμένου και στη μάθηση με ελάχιστα παραδείγματα (few-shot learning), και το BERT (Bidirectional Encoder Representations from Transformers) της Google, το οποίο διαβάζει το κείμενο αμφίδρομα για να κατανοεί καλύτερα το νόημα κάθε λέξης με βάση τα συμφραζόμενά της. Παράλληλα, μοντέλα ανοιχτού κώδικα όπως το Llama (Large Language Model Meta AI) επιτρέπουν την εξειδικευμένη εκπαίδευση (fine-tuning) για συγκεκριμένες επιχειρηματικές εφαρμογές (Touvron et al., 2023). Σε αντίθεση, λοιπόν, με τα παραδοσιακά Recommender Systems που βασίζονται κυρίως σε έμμεσα δεδομένα (implicit data), τα συστήματα που αξιοποιούν LLMs μπορούν να αντλούν πληροφορίες άμεσα από τις ρητά δηλωμένες ανάγκες και προθέσεις του χρήστη, μειώνοντας την αβεβαιότητα και ανταποκρινόμενα δυναμικά στο τρέχον πλαίσιο (context) των αναγκών του (Fan et al., 2023).

Πέρα όμως από την απλή κατανόηση, αυτό που καθιστά τα LLMs επαναστατικά είναι η ικανότητά τους να εμπλουτίζουν τον διάλογο με στοιχεία διαφάνειας και συνεργασίας. Αυτή η μετάβαση από τη μονόδρομη πρόταση στον αμφίδρομο, επεξηγηματικό διάλογο είναι που καθιστά την εμπειρία πραγματικά διαδραστική, ενισχύοντας την εμπιστοσύνη και την ικανοποίηση του χρήστη (Fan et al., 2023).

Την πρακτική μετενσάρκωση αυτών των δυνατοτήτων αποτελούν τα Συνομιλιακά Συστήματα Συστάσεων (CRS), τα οποία ενσωματώνουν μηχανισμούς διαλόγου για μια πιο άμεση και διαδραστική επικοινωνία. Όπως αναφέρουν οι Ricci et al. (2010), μέσω αυτής της επικοινωνίας το σύστημα μπορεί να υποβάλλει ερωτήσεις αποσαφήνισης, να λαμβάνει άμεση ανατροφοδότηση και να προσαρμόζει δυναμικά τις συστάσεις του. Με την ενσωμάτωση των LLMs, η ποιότητα του διαλόγου αλλάζει ριζικά: το σύστημα δεν ακολουθεί πλέον ένα προκαθορισμένο δέντρο αποφάσεων, αλλά μπορεί να διαπραγματευτεί, να εξηγήσει το σκεπτικό του ή και να αμφισβητήσει ευγενικά τον χρήστη, προσφέροντας μια εμπειρία που προσομοιάζει στη συνεργασία με έναν ανθρώπινο σύμβουλο (Fan et al., 2023). Έτσι, ο χρήστης συμβάλλει ενεργά στη διαμόρφωση των προτάσεων μέσα από μια φυσική συνομιλία, οδηγώντας σε πιο ακριβείς, σχετικές και βαθιά εξατομικευμένες προτάσεις (Jannach &

Jugovac, 2019). Χαρακτηριστικό παράδειγμα αυτής της τάσης αποτελεί ο Google Assistant, ο οποίος αξιοποιεί δεδομένα από πολλαπλές πηγές (ημερολόγιο, τοποθεσία, αλληλεπιδράσεις) για να προσφέρει προδραστικές, εξατομικευμένες συστάσεις —από εστιατόρια μέχρι διαδρομές— ενσωματώνοντας την έννοια του context-aware computing σε έναν καθημερινό βοηθό. Η λειτουργία ενός CRS απεικονίζεται στο Σχεδιάγραμμα 4.3.



Σχεδιάγραμμα 4. 3

Διάγραμμα ροής συνομιλιακού συστήματος συστάσεων (Conversational Recommender System). Ο χρήστης και το σύστημα αλληλεπιδρούν μέσω διαλόγου, με το σύστημα να υποβάλλει ερωτήσεις αποσαφήνισης και να προσαρμόζει δυναμικά τις προτάσεις βάσει της ανατροφοδότησης. ***Προσαρμογή από Jannach & Jugovac (2019) και Gao et al. (2023).***

Μια από τις πιο ενδιαφέρουσες μελλοντικές κατευθύνσεις είναι η αξιοποίηση πολυτροπικών δεδομένων (multimodal data), δηλαδή πληροφοριών που συνδυάζουν διαφορετικές αισθητηριακές μορφές - κείμενο, εικόνα, ήχο και βίντεο (Gao et al., 2023). Ενώ ένα παραδοσιακό σύστημα μπορεί να γνωρίζει ότι ένας χρήστης βαθμολόγησε θετικά ένα προϊόν, ένα πολυτροπικό σύστημα μπορεί επιπλέον να «δει» τις φωτογραφίες του, να αναλύσει τον τόνο της φωνής σε μια ηχητική κριτική ή να εντοπίσει συναισθηματικές αποχρώσεις σε ένα βίντεο unboxing. Αυτή η ικανότητα επιτρέπει την οικοδόμηση πολύ πιο ολοκληρωμένων και ακριβών προφίλ χρηστών (Zhang et al., 2019, Wang et al., 2021).

Η δύναμη της πολυτροπικής προσέγγισης έγκειται στον συνδυασμό σημάτων που από μόνα τους θα ήταν ανεπαρκή. Για παράδειγμα, σε μια πλατφόρμα ηλεκτρονικού εμπορίου, μια απλή περιγραφή «κόκκινο φόρεμα» μπορεί να εμπλουτιστεί από την ανάλυση της εικόνας του ρούχου (ύφος, μήκος, υφή) και τα σχόλια των χρηστών («τέλειο για γάμο», «το ύφασμα γυαλίζει»). Συνδυάζοντας αυτά τα σήματα, το σύστημα δεν βλέπει απλώς ένα αντικείμενο, αλλά κατανοεί καλύτερα το πλαίσιο χρήσης του και μπορεί να το προτείνει σε χρήστες που αναζητούν κάτι «κομψό» και όχι απλώς «κόκκινο». Προηγμένα μοντέλα βαθιάς μάθησης που μπορούν να επεξεργαστούν ταυτόχρονα ετερογενή δεδομένα είναι το κλειδί για να γίνουν αυτές οι προτάσεις πιο ακριβείς, σχετικές και προσαρμοσμένες στις πραγματικές ανάγκες του κάθε χρήστη (Zhang et al., 2019).

Παράλληλα, ιδιαίτερη έμφαση δίνεται στην ανάπτυξη ερμηνεύσιμων συστημάτων συστάσεων (Explainable Recommender Systems - XRS), δηλαδή συστημάτων που όχι μόνο προτείνουν, αλλά μπορούν και να εξηγήσουν με κατανοητό τρόπο το σκεπτικό πίσω από κάθε πρόταση. Η ανάγκη αυτή συνδέεται άμεσα με τη διαφάνεια, την εμπιστοσύνη και την αποδοχή των συστημάτων από τους χρήστες (Adomavicius & Tuzhilin, 2005).

Στην πράξη, μια εξήγηση μπορεί να λάβει διάφορες μορφές: από μια απλή φράση όπως «σας το προτείνουμε επειδή αγοράσατε το Χ» μέχρι μια πιο σύνθετη οπτικοποίηση που δείχνει ποια χαρακτηριστικά του προϊόντος ταιριάζουν με το προφίλ σας. Το κρίσιμο στοιχείο είναι ότι η εξήγηση δεν αποτελεί απλώς μια τεχνική λεπτομέρεια, αλλά έναν μηχανισμό ενδυνάμωσης του χρήστη: του δίνει τη δυνατότητα να καταλάβει, να αμφισβητήσει και τελικά να ελέγξει καλύτερα τη διαδικασία λήψης αποφάσεων (Zhang & Chen, 2020). Αυτή η διαφάνεια είναι που διαφοροποιεί ένα απλό εργαλείο αυτοματισμού από έναν πραγματικό σύμβουλο, και η αξία της γίνεται ακόμη πιο κρίσιμη σε τομείς υψηλής ευθύνης, όπως η υγεία και τα χρηματοοικονομικά, όπου μια απλή πρόταση χωρίς εξήγηση θα ήταν ανεπαρκής ή και επικίνδυνη. Σε τελική ανάλυση, η αποτελεσματικότητα των RS κρίνεται όχι μόνο από την πολυπλοκότητα των αλγορίθμων αλλά και από την ποιότητα της εμπειρίας χρήστη — μια μικρή αλλαγή στον σχεδιασμό της διεπαφής μπορεί συχνά να έχει μεγαλύτερο αντίκτυπο στην εμπιστοσύνη και την αποδοχή από ό,τι μια περίπλοκη βελτίωση του μοντέλου (Pu, Chen & Hu, 2012· Adomavicius & Tuzhilin, 2005).

Οι παραπάνω εξελίξεις, αν και πολλά υποσχόμενες, δημιουργούν νέα, ειδικά ζητήματα. Η κλίμακα των LLMs, με τις δεκάδες δισεκατομμύρια παραμέτρους, δεν απαιτεί απλώς τεράστιους υπολογιστικούς πόρους, αλλά εγείρει και ένα σημαντικό περιβαλλοντικό

αποτύπωμα λόγω της ενέργειας που καταναλώνεται κατά την εκπαίδευσή τους. Παράλληλα, η ευχέρειά τους να παράγουν πειστικό λόγο τα καθιστά δυνητικά επικίνδυνα για τη διάδοση πειστικής παραπληροφόρησης ή «ψευδαισθήσεων» (hallucinations), όπου το μοντέλο επινοεί ανύπαρκτα γεγονότα με απόλυτη βεβαιότητα (Fan et al., 2023). Επιπλέον, η ικανότητα των συνομιλιακών συστημάτων να προσαρμόζουν τον διάλογο σε προσωπικό επίπεδο εισάγει νέους κινδύνους χειραγώγησης, καθιστώντας αναγκαία τη θέσπιση μηχανισμών ελέγχου και διαφάνειας που θα διασφαλίζουν την ηθική και υπεύθυνη χρήση τους.

Εν κατακλείδι, οι μελλοντικές εξελίξεις ωθούν τα recommender systems πέρα από την απλή πρόβλεψη, σε έναν ρόλο ενεργού, διαδραστικού συμβούλου. Η ενσωμάτωση των LLMs και των conversational τεχνολογιών δεν υπόσχεται απλώς καλύτερες προτάσεις, αλλά μια θεμελιώδη αλλαγή στον τρόπο που οι χρήστες αλληλεπιδρούν με την πληροφορία, επαναπροσδιορίζοντας τη θέση των RS στο ψηφιακό οικοσύστημα (Gao et al., 2023). Η ενσωμάτωση αυτών των τεχνολογιών δεν αποτελεί απλώς μια ακαδημαϊκή άσκηση, αλλά μια επιτακτική ανάγκη για επιχειρήσεις που επιθυμούν να παραμείνουν ανταγωνιστικές, καθιστώντας την περιοχή αυτή ένα από τα πιο ενεργά πεδία μελλοντικής έρευνας.

5. ΚΕΦΑΛΑΙΟ 5: Μελέτη Περίπτωσης – Amazon & Netflix

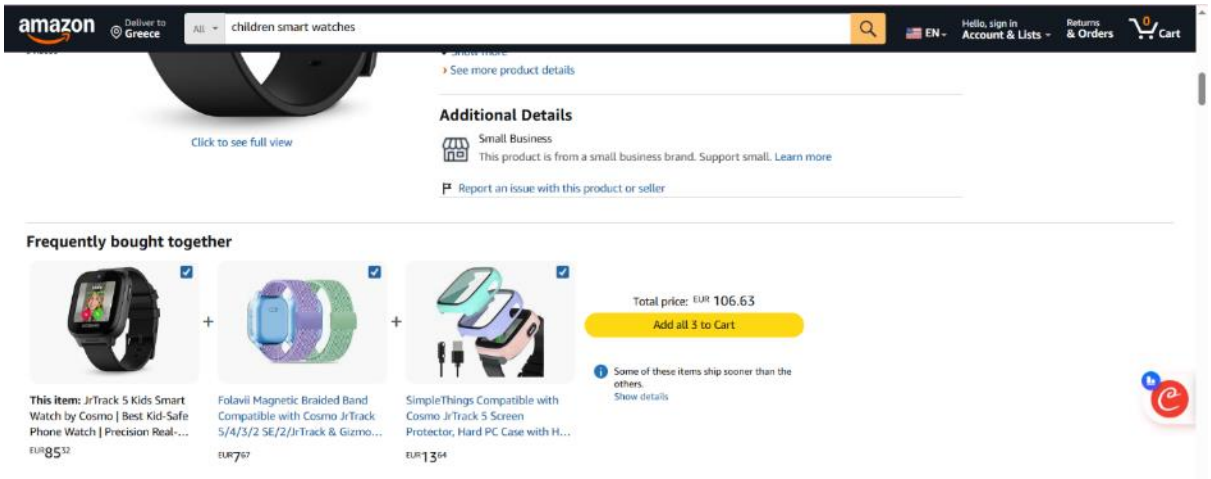
Προτού προχωρήσουμε στην επιμέρους ανάλυση, είναι σκόπιμο να ορίσουμε το ενιαίο πλαίσιο που θα εφαρμοστεί σε όλες τις μελέτες περίπτωσης της παρούσας εργασίας (Κεφάλαια 5, 6 και 7). Για λόγους συγκρισιμότητας, κάθε πλατφόρμα αναλύεται με βάση πέντε κοινούς άξονες: (α) το επιχειρησιακό πλαίσιο και το είδος της πλατφόρμας, (β) την ορατή μορφή προσωποποίησης που προσφέρει στον τελικό χρήστη, (γ) την τεχνική λογική του συστήματος, μόνο όπου αυτή τεκμηριώνεται από επίσημη ή πρωτογενή πηγή, (δ) τα επιχειρησιακά οφέλη και τους πιθανούς κινδύνους που προκύπτουν, και (ε) το επίπεδο βεβαιότητας της διαθέσιμης πληροφορίας. Η χρήση αυτού του ενιαίου πλαισίου περιορίζει την άνιση αξιολόγηση των περιπτώσεων, ιδιαίτερα μεταξύ διεθνών πλατφορμών με πλούσια τεκμηρίωση και ελληνικών παραδειγμάτων με ανάλυση βασισμένη σε δημόσια διαθέσιμες πληροφορίες, και επιτρέπει την εξαγωγή συγκριτικών συμπερασμάτων.

5.1.Εταιρικό Προφίλ, Στρατηγική και Προκλήσεις Προσωποποίησης

Η μελέτη των περιπτώσεων της Amazon και του Netflix αποτελεί χαρακτηριστικό παράδειγμα επιτυχημένης αξιοποίησης των συστημάτων συστάσεων σε δύο διαφορετικά επιχειρηματικά περιβάλλοντα. Παρότι οι δύο εταιρείες δραστηριοποιούνται σε διαφορετικούς τομείς, η Amazon στο ηλεκτρονικό εμπόριο και το Netflix στο streaming ψυχαγωγίας, και οι δύο έχουν ενσωματώσει την προσωποποίηση ως βασικό στοιχείο της επιχειρηματικής και ψηφιακής στρατηγικής τους.

Η Amazon συγκαταλέγεται στις μεγαλύτερες πλατφόρμες ηλεκτρονικού εμπορίου παγκοσμίως, προσφέροντας ένα ιδιαίτερα ευρύ φάσμα προϊόντων και υπηρεσιών, από βιβλία, ηλεκτρονικά είδη, ένδυση και τρόφιμα έως υπηρεσίες cloud. Η στρατηγική της βασίζεται σε μεγάλο βαθμό στη διαχείριση και αξιοποίηση τεράστιου όγκου δεδομένων χρηστών, με στόχο τη δημιουργία εξατομικευμένων προτάσεων που διευκολύνουν τη διαδικασία αγοράς.
Η προσωποποίηση εφαρμόζεται σε πολλαπλά σημεία της πλατφόρμας, όπως στην αρχική σελίδα, στις σελίδες προϊόντων και στις καμπάνιες marketing. Χαρακτηριστικές είναι οι προτάσεις τύπου «όσοι αγόρασαν αυτό, αγόρασαν επίσης…», οι οποίες βασίζονται σε δεδομένα όπως το ιστορικό αγορών, οι αναζητήσεις και οι αλληλεπιδράσεις των χρηστών

(Linden et al., 2003). Η προσέγγιση αυτή επιτρέπει στην Amazon να παρέχει στοχευμένες προτάσεις σε πραγματικό χρόνο, ενισχύοντας τη συνάφεια των επιλογών που εμφανίζονται στον χρήστη και αυξάνοντας την πιθανότητα ολοκλήρωσης μιας αγοράς. Χαρακτηριστικό παράδειγμα cross selling παρουσιάζεται στην Εικόνα 5.1.

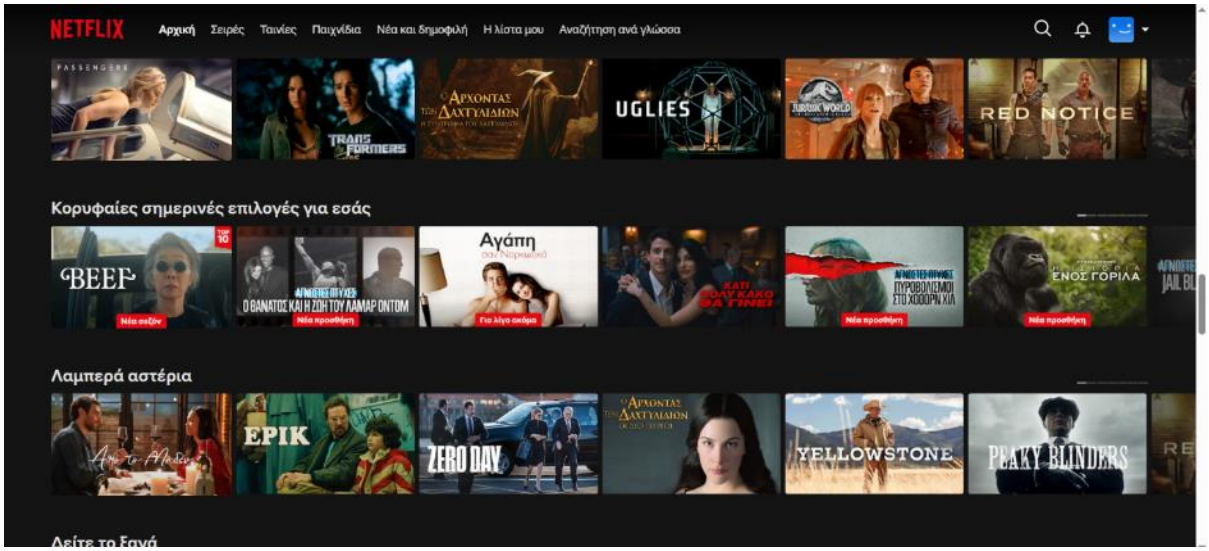


Εικόνα 5. 1

Παράδειγμα cross-selling στην Amazon με την ενότητα «Frequently bought together». Το σύστημα προτείνει συμπληρωματικά προϊόντα βασισμένο σε συμπεριφορές άλλων χρηστών. *Προσαρμογή από Linden et al. (2003). Πηγή: Amazon (screenshot από τον συγγραφέα, Μάιος 2026)*

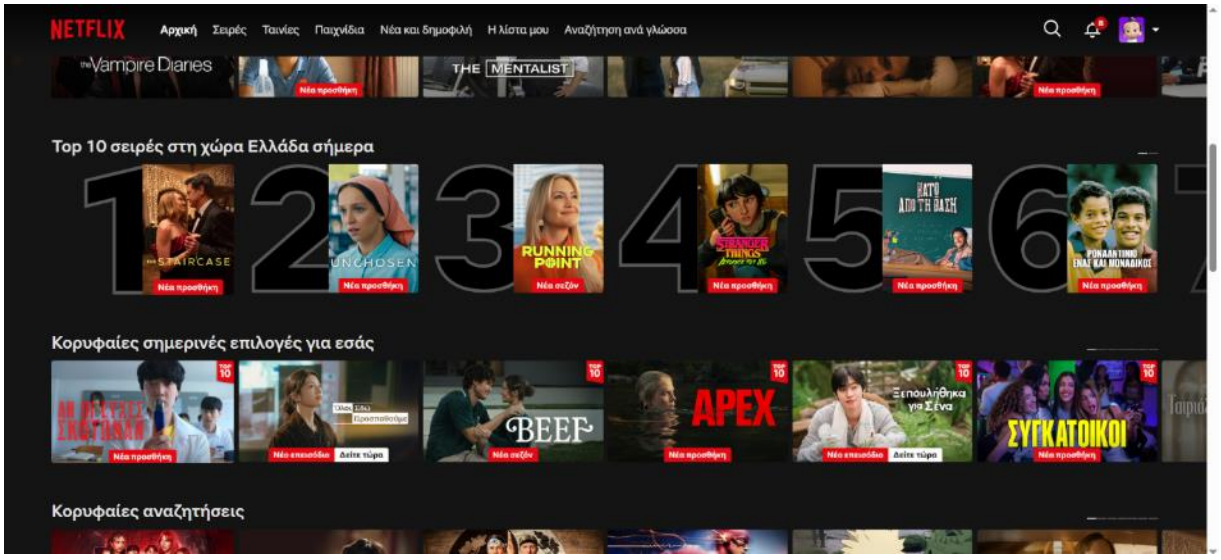
Από την άλλη, το Netflix δραστηριοποιείται στον τομέα της ψηφιακής ψυχαγωγίας, προσφέροντας υπηρεσίες streaming περιεχομένου, όπως ταινίες, σειρές και ντοκιμαντέρ, σε παγκόσμιο επίπεδο. Η επιτυχία της πλατφόρμας συνδέεται σε μεγάλο βαθμό με την ικανότητά της να προτείνει περιεχόμενο που ανταποκρίνεται στις ιδιαίτερες προτιμήσεις κάθε χρήστη.
Η στρατηγική προσωποποίησης του Netflix βασίζεται στην ανάλυση δεδομένων προβολής, όπως η διάρκεια θέασης, οι παύσεις, οι επαναλήψεις και η εγκατάλειψη περιεχομένου. Παράλληλα, αξιοποιούνται πληροφορίες που σχετίζονται με τις επιλογές του χρήστη, όπως τα είδη περιεχομένου που προτιμά, οι ηθοποιοί, οι σκηνοθέτες και τα γενικότερα μοτίβα κατανάλωσης. Αξίζει να σημειωθεί πως, λόγω των RS, η πλατφόρμα δεν περιορίζεται μόνο στην πρόταση τίτλων, αλλά προσαρμόζει δυναμικά και τον τρόπο με τον οποίο παρουσιάζεται το περιεχόμενο. Αυτό περιλαμβάνει εξατομικευμένες λίστες, όπως «Επειδή παρακολουθήσατε…», διαφορετικές εικόνες προεπισκόπησης (thumbnails) για τον ίδιο τίτλο ανάλογα με το προφίλ του χρήστη, καθώς και διαφοροποίηση στη σειρά εμφάνισης του περιεχομένου (Gomez-Uribe & Hunt, 2015). Οι Εικόνες 5.2 και 5.3 απεικονίζουν ενδεικτικά

τον τρόπο με τον οποίο η προσωποποίηση εφαρμόζεται στην πλατφόρμα, όπου στην ίδια κατηγορία «Κορυφαίες σημερινές επιλογές για εσάς» εμφανίζει προσωποποιημένες προτάσεις για διαφορετικούς χρήστες



Εικόνα 5. 2

Εξατομίκευση περιεχομένου στο Netflix. Η πλατφόρμα δημιουργεί δυναμικές λίστες προτάσεων βασισμένες στο ιστορικό προβολών και προσαρμόζει ακόμα και τις εικόνες προεπισκόπησης (thumbnails) ανάλογα με τα ενδιαφέροντα του χρήστη. *Προσαρμογή από Gomez-Uribe & Hunt (2015). Πηγή: Netflix (screenshot από τον συγγραφέα, Μάιος 2026)*



Εικόνα 5. 3

Εξατομίκευση περιεχομένου στο Netflix. Η πλατφόρμα δημιουργεί δυναμικές λίστες προτάσεων βασισμένες στο ιστορικό προβολών και προσαρμόζει ακόμα και τις εικόνες προεπισκόπησης (thumbnails) ανάλογα με τα

ενδιαφέροντα του χρήστη. *Προσαρμογή από Gomez-Uribe & Hunt (2015). Πηγή: Netflix (screenshot από τον συγγραφέα, Μάιος 2026)*

Παρά τις διαφορές τους, οι δύο πλατφόρμες μοιράζονται ένα κοινό θεμελιώδες χαρακτηριστικό: τη στρατηγική αξιοποίηση των δεδομένων για τη συνεχή βελτίωση των προτάσεων. Και στις δύο περιπτώσεις, η εξατομίκευση δεν αντιμετωπίζεται ως απλό τεχνολογικό πρόσθετο, αλλά ως θεμελιώδης πυλώνας της συνολικής στρατηγικής τους. Είναι κοινά παραδεκτό πως επηρεάζεται άμεσα η συνολική εμπειρία του χρήστη, η σχέση του με την πλατφόρμα και η δημιουργία επιχειρησιακής αξίας (Jannach & Jugovac, 2019). Μέσα από τη συνεχή συλλογή και ανάλυση δεδομένων, τα συστήματα συστάσεων μπορούν να προσαρμόζονται δυναμικά στις μεταβαλλόμενες προτιμήσεις των χρηστών, διατηρώντας τις προτάσεις σχετικές, επίκαιρες και χρήσιμες.

Παρ' όλα αυτά, οι στρατηγικές αυτές συνοδεύονται αναπόφευκτα από γνωστές προκλήσεις, οι οποίες έχουν ήδη αναλυθεί εκτενώς στο θεωρητικό πλαίσιο της παρούσας εργασίας. Συνοπτικά, η ανάγκη για λειτουργία σε πραγματικό χρόνο και παγκόσμια κλίμακα πιέζει διαρκώς τα όρια της υπολογιστικής επεκτασιμότητας, ενώ η εκτεταμένη χρήση δεδομένων εγείρει αυστηρά ζητήματα ιδιωτικότητας και κανονιστικής συμμόρφωσης. Παράλληλα, και οι δύο πλατφόρμες αντιμετωπίζουν ενεργά τον κίνδυνο της υπερ-εξειδίκευσης (over-specialization), ενσωματώνοντας στους αλγορίθμους τους μηχανισμούς ανακάλυψης —όπως ενότητες δημοφιλούς περιεχομένου ή τυχαίες προτάσεις— για να αντισταθμίσουν την τάση προς μια ομοιόμορφη εμπειρία (Fleder & Hosanagar, 2009).

Η ικανότητά τους να αναγνωρίζουν και να διαχειρίζονται αυτές τις προκλήσεις, αντί να τις αγνοούν, είναι αυτή που τελικά διαφοροποιεί την επιτυχημένη από την απλώς λειτουργική ενσωμάτωση των recommender systems. Αυτό επιβεβαιώνει ότι η προσωποποίηση δεν είναι μια αυτοματοποιημένη διαδικασία, αλλά μια δυναμική στρατηγική που απαιτεί συνεχή επίβλεψη, ηθική κρίση και προσαρμογή.

5.2. Χρήση των Recommender Systems στην Εμπειρία Χρήστη

Η αξιοποίηση των συστημάτων συστάσεων στην εμπειρία χρήστη αποτελεί βασικό παράγοντα επιτυχίας τόσο για την Amazon όσο και για το Netflix. Σε ψηφιακά περιβάλλοντα

όπου ο όγκος των διαθέσιμων επιλογών είναι ιδιαίτερα μεγάλος, τα recommender systems λειτουργούν ως μηχανισμοί καθοδήγησης, καθώς μειώνουν την πολυπλοκότητα της επιλογής και ενισχύουν τη συνολική εμπειρία του χρήστη (Pu et al., 2012).

Στην περίπτωση της Amazon, τα συστήματα συστάσεων ενσωματώνονται σε πολλά διαφορετικά σημεία της πλατφόρμας. Εμφανίζονται στην αρχική σελίδα, μέσα από εξατομικευμένες ενότητες όπως «Προτεινόμενα για εσάς», στις σελίδες προϊόντων, μέσω προτάσεων τύπου «Όσοι αγόρασαν αυτό, αγόρασαν επίσης…», αλλά και στο καλάθι αγορών, με ενότητες όπως «Συχνά αγοράζονται μαζί». Επιπλέον, αξιοποιούνται σε e-mails και ειδοποιήσεις, για παράδειγμα με υπενθυμίσεις για προϊόντα που ο χρήστης άφησε στο καλάθι ή με σχετικές προσφορές. Όπως αναφέρουν οι Linden et al. (2003), τα δεδομένα που αξιοποιεί η Amazon περιλαμβάνουν το ιστορικό αγορών, τις αναζητήσεις, τις προβολές προϊόντων, τον χρόνο παραμονής σε κάθε σελίδα, καθώς και τις προσθήκες ή αφαιρέσεις προϊόντων από το καλάθι. Με βάση αυτά τα δεδομένα, η πλατφόρμα μπορεί να προσφέρει προτάσεις σε πραγματικό χρόνο, μειώνοντας τον χρόνο αναζήτησης και αυξάνοντας την πιθανότητα ολοκλήρωσης μιας αγοράς. Για παράδειγμα, ένας χρήστης που αναζητά λαμπάκια χριστουγεννιάτικου δέντρου μπορεί να δει προτάσεις για παρόμοια λαμπάκια, και άλλα παρεμφερή, όπως δέντρο ή στολίδια, καθώς και επιλογές που βασίζονται σε αγορές άλλων χρηστών με παρόμοιο προφίλ. Ένα τέτοιο παράδειγμα παρουσιάζεται παραπάνω στην Εικόνα 5.1, όπου απεικονίζεται η τακτική cross-selling στην Amazon με την ενότητα «Customers who bought this item also bought». Εδώ το σύστημα προτείνει συμπληρωματικά προϊόντα βασισμένο σε συμπεριφορές άλλων χρηστών.

Σχετικά με το Netflix, τα συστήματα συστάσεων αποτελούν τον βασικό μηχανισμό οργάνωσης και προβολής του περιεχομένου. Η πλατφόρμα δεν παρουσιάζει έναν στατικό κατάλογο ταινιών και σειρών, αλλά δημιουργεί δυναμικές και εξατομικευμένες λίστες για κάθε χρήστη. Ενδεικτικά, εμφανίζονται κατηγορίες όπως «Επειδή παρακολουθήσατε…», «Δημοφιλή στο Netflix», «Top 10 στην Ελλάδα σήμερα» ή προτάσεις που βασίζονται σε συγκεκριμένους ηθοποιούς, είδη ή προηγούμενες επιλογές του χρήστη. Επιπλέον, το Netflix εφαρμόζει προσωποποίηση όχι μόνο στο περιεχόμενο που προτείνεται, αλλά και στον τρόπο με τον οποίο αυτό παρουσιάζεται. Για τον ίδιο τίτλο μπορεί να εμφανίζονται διαφορετικές εικόνες προεπισκόπησης (thumbnails), ανάλογα με τις προτιμήσεις του χρήστη. Για παράδειγμα, ένας χρήστης που προτιμά ρομαντικές ταινίες μπορεί να δει μια εικόνα που τονίζει μια συναισθηματική σκηνή, ενώ ένας χρήστης που προτιμά ταινίες δράσης μπορεί να

δει μια σκηνή με ένταση ή δράση. Αξίζει, επιπλέον, να αναφερθεί πως η πλατφόρμα διαφοροποιεί τη σειρά εμφάνισης των κατηγοριών και αξιοποιεί auto-play previews κατά την πλοήγηση (Gomez-Uribe & Hunt, 2015). Χαρακτηριστικά, δύο διαφορετικοί χρήστες που βλέπουν την ίδια ταινία, όπως το *Kung Fu Panda 4*, μπορεί να δουν διαφορετική εικόνα προεπισκόπησης ή να συναντήσουν την ίδια πρόταση σε διαφορετική κατηγορία. Για έναν χρήστη η ταινία μπορεί να εμφανιστεί στην κατηγορία «Παιδικά», ενώ για κάποιον άλλον στην κατηγορία «Ταινίες Δράσης», ανάλογα με το προφίλ και το ιστορικό θέασής του. Κοινό στοιχείο και στις δύο πλατφόρμες είναι η συνεχής προσαρμογή της εμπειρίας μέσω των δεδομένων. Τα συστήματα συστάσεων δεν λειτουργούν στατικά, αλλά εξελίσσονται με κάθε νέα αλληλεπίδραση, όπως ένα click, μια προβολή, μια αγορά, μια παύση ή μια εγκατάλειψη περιεχομένου. Όσο περισσότερο χρησιμοποιεί ο χρήστης την πλατφόρμα, τόσο περισσότερο εμπλουτίζεται το προφίλ του και τόσο βελτιώνεται η ακρίβεια των προτάσεων.

Θα αποτελούσε σοβαρή παράλειψη να μην τονίσουμε πως, η χρήση των RS συμβάλλει επίσης στην αύξηση της εμπλοκής των χρηστών (engagement). Στην Amazon, αυτό μπορεί να εκφραστεί μέσα από περισσότερες προβολές προϊόντων, μεγαλύτερο χρόνο πλοήγησης και υψηλότερα ποσοστά μετατροπής. Στο Netflix, αντίστοιχα, συνδέεται με αυξημένο χρόνο παραμονής στην πλατφόρμα και μείωση του churn rate, δηλαδή της αποχώρησης συνδρομητών (Jannach & Jugovac, 2019).

Ωστόσο, η έντονη χρήση συστημάτων συστάσεων συστημάτων συστάσεων ενέχει τον κίνδυνο μείωσης της ποικιλίας των προτάσεων, γεγονός που έχει τεκμηριωθεί εμπειρικά σε μεγάλες πλατφόρμες (Fleder and Hosanagar, 2009). Για τον λόγο αυτό, και οι δύο πλατφόρμες ενσωματώνουν μηχανισμούς ανακάλυψης που ανανεώνουν και διαφοροποιούν τις προτάσεις.

Εύκολα, λοιπόν, οδηγούμαστε στο συμπέρασμα, η χρήση των recommender systems στην εμπειρία χρήστη αποτελεί βασικό στοιχείο διαφοροποίησης τόσο για την Amazon όσο και για το Netflix. Επιτρέπει τη δημιουργία ενός δυναμικού και εξατομικευμένου περιβάλλοντος, το οποίο ενισχύει την ικανοποίηση των χρηστών, αυξάνει τη δέσμευσή τους και οδηγεί σε υψηλότερη εμπορική και επιχειρησιακή απόδοση.

5.3. Τεχνολογική Προσέγγιση (Τύποι Συστάσεων και Αλγόριθμοι)

Η τεχνολογική υλοποίηση των συστημάτων συστάσεων στην Amazon και στο Netflix βασίζεται στον συνδυασμό διαφορετικών μεθόδων, οι οποίες προσαρμόζονται στις ανάγκες και στις ιδιαιτερότητες κάθε επιχειρηματικού μοντέλου. Και στις δύο περιπτώσεις, η παραγωγή προτάσεων δεν στηρίζεται σε μία μόνο τεχνική, αλλά σε υβριδικά συστήματα που συνδυάζουν collaborative filtering, content-based filtering και προηγμένες τεχνικές μηχανικής μάθησης, όπως matrix factorization, deep learning και embeddings.

Στην περίπτωση της Amazon, η τεχνολογική προσέγγιση βασίζεται κυρίως στο collaborative filtering, με ιδιαίτερη έμφαση στο item-based μοντέλο. Αντί το σύστημα να αναζητά κυρίως χρήστες με παρόμοια συμπεριφορά, όπως συμβαίνει στις user-based προσεγγίσεις, εστιάζει στον εντοπισμό ομοιοτήτων μεταξύ προϊόντων. Με άλλα λόγια, η πιθανότητα να προταθεί ένα προϊόν εξαρτάται από το πόσο συχνά αυτό συνδέεται με άλλα προϊόντα μέσα από τις αγορές, τις προβολές ή τις αλληλεπιδράσεις των χρηστών. Η προσέγγιση αυτή παρουσιάζει σημαντικά πλεονεκτήματα για μια πλατφόρμα μεγάλης κλίμακας όπως η Amazon. Επιτρέπει την αποτελεσματική διαχείριση πολύ μεγάλων καταλόγων προϊόντων, που περιλαμβάνουν εκατομμύρια κωδικούς, υποστηρίζει την παραγωγή προτάσεων σε πραγματικό χρόνο και προσφέρει καλύτερη επεκτασιμότητα σε σχέση με τις user-based προσεγγίσεις (Linden et al., 2003). Για παράδειγμα, όταν ένας χρήστης αγοράζει ή αναζητά ένα smartphone, το σύστημα μπορεί να του προτείνει άλλα smartphones με παρόμοια χαρακτηριστικά, όπως ίδια μάρκα ή αντίστοιχες τεχνικές προδιαγραφές. Παράλληλα, μπορεί να εμφανίσει συμπληρωματικά προϊόντα που έχουν αγοράσει άλλοι χρήστες μαζί με το συγκεκριμένο κινητό, όπως θήκες, προστατευτικά τζάμια ή φορτιστές. Χρειάζεται επίσης να σημειωθεί πως η Amazon δεν περιορίζεται αποκλειστικά στο item-based collaborative filtering. Σε έναν κατάλογο που αριθμεί δισεκατομμύρια προϊόντα, οι αλληλεπιδράσεις των χρηστών είναι αναπόφευκτα αραιές, γεγονός που σημαίνει ότι πολλά αντικείμενα δεν μπορούν να συνδεθούν αξιόπιστα μόνο μέσω της συμπεριφοράς των χρηστών. Για τον λόγο αυτό, η Amazon αξιοποιεί και content-based τεχνικές, οι οποίες βασίζονται στην ανάλυση κατηγοριών, περιγραφών και τεχνικών χαρακτηριστικών των προϊόντων. Επιπλέον, ενσωματώνει το matrix factorization για να ανακαλύψει λανθάνουσες σχέσεις μεταξύ χρηστών και προϊόντων (Koren et al., 2009), καθώς και τεχνικές deep learning που της επιτρέπουν να επεξεργάζεται σύνθετα

δεδομένα (π.χ. κείμενο, εικόνες προϊόντων) και να παράγει ακριβέστερες προτάσεις, ιδιαίτερα όταν τα δεδομένα αλληλεπίδρασης είναι περιορισμένα (Zhang et al., 2019).

Αναφορικά με το Netflix, η τεχνολογική προσέγγιση είναι ακόμη πιο σύνθετη, καθώς η πλατφόρμα καλείται να προτείνει περιεχόμενο που συνδέεται όχι μόνο με προηγούμενες επιλογές, αλλά και με πιο σύνθετες προτιμήσεις, όπως είδος, ύφος, ηθοποιοί, σκηνοθέτες και μοτίβα θέασης. Σύμφωνα με τους Gomez-Uribe και Hunt (2015), το Netflix αξιοποιεί collaborative filtering για την ανάλυση των προτιμήσεων των χρηστών, content-based μεθόδους που βασίζονται σε μεταδεδομένα περιεχομένου, καθώς και υβριδικά μοντέλα που συνδυάζουν τις παραπάνω προσεγγίσεις.

Μία από τις βασικές τεχνικές που χρησιμοποιούνται είναι τα embeddings, Μέσα από αυτές τις αναπαραστάσεις, όπως αναλύθηκαν παραπάνω, η ομοιότητα μεταξύ χρηστών και περιεχομένου μπορεί να υπολογιστεί με μετρικές όπως η cosine similarity ή το εσωτερικό γινόμενο. Με αυτόν τον τρόπο, το σύστημα μπορεί να εντοπίζει σχέσεις που δεν είναι άμεσα εμφανείς, όπως κοινά στοιχεία μεταξύ διαφορετικών ταινιών ή σειρών που προσελκύουν παρόμοιους χρήστες. Επιπλέον, ιδιαίτερη σημασία έχουν τα ranking models, δηλαδή τα μοντέλα κατάταξης. Στην πράξη, δεν αρκεί το σύστημα να εντοπίσει σχετικές προτάσεις, πρέπει και να τις παρουσιάσει με τη σωστή σειρά. Για τον λόγο αυτό, το Netflix αξιοποιεί personalized ranking, όπως το Bayesian Personalized Ranking (BPR), ώστε να εκτιμήσει ποιος τίτλος έχει τη μεγαλύτερη πιθανότητα να επιλεγεί ή να προβληθεί από τον χρήστη στη συνέχεια. Ένα ακόμη σημαντικό στοιχείο της τεχνολογικής προσέγγισης του Netflix είναι η δυνατότητα real-time ενημέρωσης και online learning. Κάθε νέα προβολή, παύση, επανάληψη ή εγκατάλειψη περιεχομένου μπορεί να ενημερώνει άμεσα το μοντέλο, επιτρέποντας στο σύστημα να προσαρμόζεται γρήγορα στις μεταβαλλόμενες προτιμήσεις του χρήστη. Η δυνατότητα αυτή είναι ιδιαίτερα σημαντική σε μια πλατφόρμα streaming, όπου οι επιλογές και η διάθεση του χρήστη μπορεί να αλλάζουν συχνά.

Παρά τις διαφοροποιήσεις τους, και οι δύο εταιρείες βασίζονται σε υβριδικές τεχνολογικές προσεγγίσεις και αξιοποιούν δεδομένα σε πραγματικό χρόνο. Τα συστήματα συστάσεων ενημερώνονται συνεχώς και προσαρμόζουν δυναμικά τις προτάσεις τους ανάλογα με τη συμπεριφορά του χρήστη. Για παράδειγμα, αν ένας χρήστης αναζητήσει «ποδήλατο», οι προτάσεις που εμφανίζονται στην πλατφόρμα μπορούν να αλλάξουν άμεσα, ώστε να ανταποκριθούν στη νέα ένδειξη ενδιαφέροντος. Με τον τρόπο αυτό, τα RS λειτουργούν ως

δυναμικά και εξελισσόμενα συστήματα, τα οποία προσαρμόζονται διαρκώς στο προφίλ και στις ανάγκες κάθε χρήστη. Η σύγκριση μεταξύ Amazon και Netflix συνοψίζεται στον Πίνακα 5.1, όπου παρουσιάζονται οι βασικές διαφορές ως προς την κύρια τεχνική, τις επιπλέον τεχνολογικές προσεγγίσεις, το είδος των δεδομένων που αξιοποιούνται, τη δυνατότητα real-time προσαρμογής και την κύρια πρόκληση κάθε πλατφόρμας.

Χαρακτηριστικό	Amazon	Netflix
Κύρια τεχνική	Item-based collaborative filtering	Υβριδικά μοντέλα (CF + content-based)
Επιπλέον τεχνικές	Matrix factorization, content-based, deep learning	Embeddings, ranking models, deep learning
Είδος δεδομένων	Αγορές, αναζητήσεις, clicks, χρόνος παραμονής	Προβολές, παύσεις, επαναλήψεις, εγκαταλείψεις
Real-time	Ναι (online updates)	Ναι (online learning)
Κύρια πρόκληση	Τεράστιος κατάλογος προϊόντων (εκατομμύρια SKU)	Δυναμικές προτιμήσεις, τεράστιος όγκος δεδομένων

Πίνακας 5. 1 Σύγκριση τεχνολογικής προσέγγισης Amazon vs Netflix

Γίνεται, επομένως, εύκολα αντιληπτό πως η τεχνολογική προσέγγιση της Amazon και του Netflix βασίζεται στη χρήση υβριδικών μοντέλων, στην ενσωμάτωση πολλαπλών πηγών δεδομένων και στην αξιοποίηση προηγμένων τεχνικών μηχανικής μάθησης. Η συνδυαστική αυτή στρατηγική επιτρέπει στις δύο πλατφόρμες να παράγουν προτάσεις υψηλής ποιότητας, οι οποίες ανταποκρίνονται με μεγαλύτερη ακρίβεια στις ανάγκες, τις προτιμήσεις και τη συμπεριφορά των χρηστών.

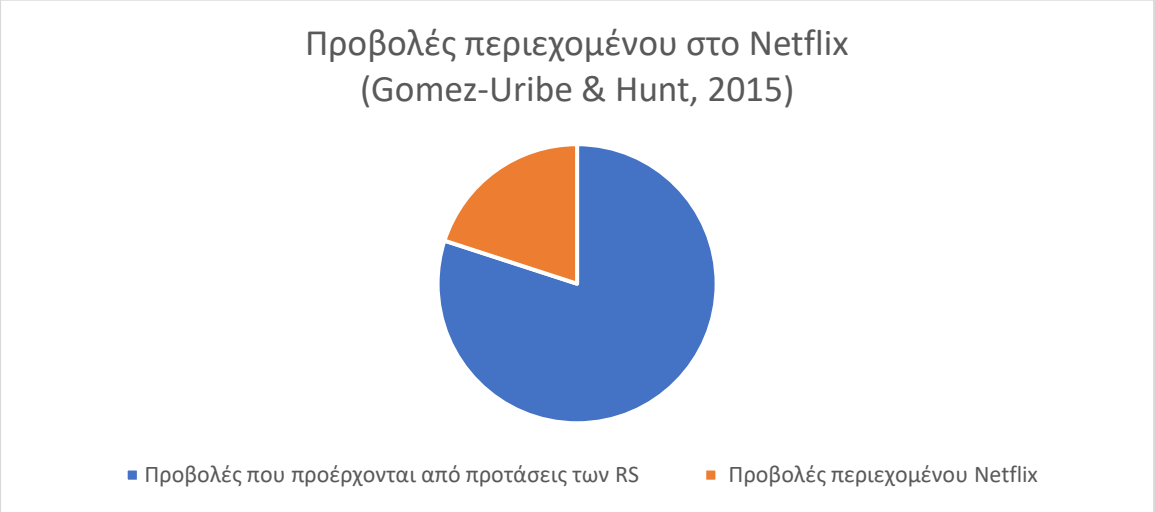
5.4.Επιχειρησιακά Αποτελέσματα

Η ενσωμάτωση συστημάτων συστάσεων στις μεγάλες ψηφιακές πλατφόρμες δεν είναι απλώς μια τεχνολογική επιλογή, αλλά ο κύριος μοχλός εσόδων και δέσμευσης. Τα διαθέσιμα

στοιχεία είναι αποκαλυπτικά: περίπου το 35% των πωλήσεων της Amazon προέρχεται από διασταυρούμενες πωλήσεις και προτάσεις (MacKenzie, Meyer & Noble, 2013), ενώ περίπου το 80% των προβολών στο Netflix και το 60% των κλικ στην αρχική οθόνη του YouTube προέρχονται από αλγοριθμικές προτάσεις (Gomez-Uribe & Hunt, 2015). Τα νούμερα αυτά καταδεικνύουν ότι τα recommender systems είναι, στην πράξη, η κύρια πηγή αλληλεπίδρασης του χρήστη με το περιεχόμενο.

Σχετικά με την Amazon, τα συστήματα συστάσεων συμβάλλουν σημαντικά στην αύξηση των πωλήσεων, βελτιστοποιώντας τη διαδικασία αγοράς και καθιστώντας τις προτάσεις πιο στοχευμένες. Μέσω της προσωποποίησης, η πλατφόρμα μπορεί να αυξήσει τα ποσοστά μετατροπής, καθώς ο χρήστης εκτίθεται σε προϊόντα που είναι πιθανότερο να ανταποκρίνονται στις ανάγκες του, ενώ ταυτόχρονα υποστηρίζονται στρατηγικές upselling και cross selling που αυξάνουν το μέσο καλάθι αγορών. Σύμφωνα με στοιχεία που δημοσίευσε η McKinsey & Company (2013), εκτιμάται ότι περίπου το 35% των αγορών στην Amazon προέρχεται από εξατομικευμένες προτάσεις, αποτέλεσμα που αντικατοπτρίζει την τεχνολογική προσέγγιση που περιέγραψαν οι Linden et al. (2003). Επιπλέον, η συνολικά βελτιωμένη εμπειρία χρήστη ενισχύει την πιθανότητα επαναλαμβανόμενων αγορών και, επομένως, τη διατήρηση πελατών (customer retention).

Στην περίπτωση του Netflix, τα επιχειρησιακά αποτελέσματα των συστημάτων συστάσεων συνδέονται κυρίως με την αύξηση της δέσμευσης των χρηστών και τη διατήρηση των συνδρομητών. Το σύστημα συστάσεων επηρεάζει την επιλογή περιεχομένου σε περίπου το 80% των ωρών παρακολούθησης, ενώ η αποτελεσματική εξατομίκευση εκτιμάται ότι συμβάλλει σε εξοικονόμηση άνω του 1 δισ. δολαρίων ετησίως, κυρίως μέσω της μείωσης του churn rate (Gomez-Uribe & Hunt, 2015), όπως απεικονίζεται και στο Σχεδιάγραμμα 5.1. Το στοιχείο αυτό αναδεικνύει τον καθοριστικό ρόλο των συστάσεων στη συνολική επιτυχία της υπηρεσίας.



Σχεδιάγραμμα 5. 1

Ποσοστό περιεχομένου που προβάλλεται στο Netflix μέσω των συστημάτων συστάσεων. Σύμφωνα με τους Gomez-Uribe & Hunt (2015), περίπου το 80% των προβολών προέρχεται από εξατομικευμένες προτάσεις του RS. Προσαρμογή από Gomez-Uribe & Hunt (2015).

Επιπλέον, οι εξατομικευμένες προτάσεις συμβάλλουν στη μείωση του χρόνου αναζήτησης περιεχομένου. Όπως τεκμηριώνεται από τα δεδομένα της πλατφόρμας, ο μέσος χρήστης χάνει το ενδιαφέρον του μετά από 60 έως 90 δευτερόλεπτα άκαρπης περιήγησης, έχοντας εξετάσει μόλις 10 έως 20 τίτλους (Gomez-Uribe & Hunt, 2015). Η ταχύτερη ανακάλυψη κατάλληλου περιεχομένου βελτιώνει την εμπειρία χρήστη και μειώνει την πιθανότητα εγκατάλειψης της πλατφόρμας. Σε αυτό ακριβώς το πλαίσιο, η χρήση εξατομικευμένων εικόνων προεπισκόπησης (thumbnails) αποτελεί χαρακτηριστικό παράδειγμα: μπορεί να αυξήσει τα ποσοστά προβολής έως και 30%, προσαρμόζοντας την οπτική παρουσίαση μιας ταινίας στο ατομικό προφίλ του χρήστη (Gomez-Uribe & Hunt, 2015).

Πέρα από τα επιμέρους αποτελέσματα, η σύγκριση Amazon και Netflix αποκαλύπτει μια σειρά από κοινά μοτίβα επιτυχίας που αναδεικνύουν τον στρατηγικό ρόλο των δεδομένων και της συνεχούς βελτιστοποίησης. Για αρχή, κοινό χαρακτηριστικό της Amazon και του Netflix είναι η συστηματική αξιοποίηση δεδομένων σε πραγματικό χρόνο. Τα δεδομένα αυτά χρησιμοποιούνται όχι μόνο για την παραγωγή εξατομικευμένων προτάσεων, αλλά και για τη βαθύτερη κατανόηση της συμπεριφοράς των χρηστών. Μέσα από την παρακολούθηση των αλληλεπιδράσεων, των επιλογών και των προτιμήσεων, οι δύο εταιρείες μπορούν να προσαρμόζουν δυναμικά τα συστήματά τους και να βελτιώνουν συνεχώς την εμπειρία

χρήστη. Άρα, τα δεδομένα αυτά υποστηρίζουν τη λήψη στρατηγικών αποφάσεων, όπως για παράδειγμα ποια προϊόντα, υπηρεσίες ή είδη περιεχομένου αξίζει να αναπτυχθούν περαιτέρω. Επιπλέον, η συνεχής βελτιστοποίηση των αλγορίθμων, μέσω πρακτικών όπως το A/B testing, επιτρέπει στις πλατφόρμες να αξιολογούν ποια μορφή πρότασης, κατάταξης ή παρουσίασης είναι πιο αποτελεσματική για τους χρήστες (Jannach & Jugovac, 2019).

Ένα ακόμη κοινό όφελος που προκύπτει από τη χρήση συστημάτων συστάσεων είναι η ικανότητα ανάδειξης λιγότερο προβεβλημένων επιλογών. Αντί η ζήτηση να συγκεντρώνεται αποκλειστικά στα πιο δημοφιλή προϊόντα ή τους πιο γνωστούς τίτλους, τα RS επιτρέπουν την προώθηση αντικειμένων που ανήκουν στη λεγόμενη «μακρά ουρά» (long tail), δηλαδή σε εκείνα που απευθύνονται σε εξειδικευμένα γούστα και μικρότερα κοινά (Anderson, 2006). Η δυνατότητα αυτή μεταφράζεται σε συγκεκριμένα οφέλη και για τις δύο πλατφόρμες, αν και με διαφορετικό τρόπο, όπως συνοψίζεται στον παρακάτω πίνακα 5.4:

Amazon	Netflix
Προώθηση λιγότερο δημοφιλών προϊόντων (long tail)	Ανάδειξη «κρυμμένων διαμαντιών» (lesser-known titles)
Μείωση απούλητων αποθεμάτων	Μείωση κόστους απόκτησης περιεχομένου (αγορά μόνο όσων έχουν ζήτηση)

Πίνακας 5. 2: Οφέλη Χρήσης RS σε Amazon και Netflix.

Η επίτευξη των παραπάνω επιχειρησιακών αποτελεσμάτων προϋποθέτει προσεκτικό σχεδιασμό και συνεχή παρακολούθηση των συστημάτων συστάσεων. Η σωστή σχεδίαση των αλγορίθμων, η διαρκής βελτιστοποίηση μέσω πρακτικών όπως το A/B testing και το online learning, καθώς και η υψηλή ποιότητα των δεδομένων αποτελούν κρίσιμους παράγοντες για την αποτελεσματική λειτουργία των RS. Αντίθετα, λανθασμένες ή μη σχετικές προτάσεις μπορούν να οδηγήσουν σε μείωση της εμπιστοσύνης προς την πλατφόρμα, σε εγκατάλειψη της υπηρεσίας ή ακόμη και σε απώλεια εσόδων, υπογραμμίζοντας ότι η ποιότητα των συστάσεων δεν αποτελεί απλώς τεχνικό ζήτημα, αλλά άμεσο παράγοντα επιχειρησιακής απόδοσης.

Συμπερασματικά, τα επιχειρησιακά αποτελέσματα από τη χρήση recommender systems στην Amazon και στο Netflix αναδεικνύουν τη στρατηγική σημασία των τεχνολογιών αυτών. Στην

περίπτωση της Amazon, τα RS συμβάλλουν κυρίως στην αύξηση των εσόδων, στη βελτίωση των conversion rates και στην ενίσχυση του μέσου καλαθιού αγορών. Αντίστοιχα, στο Netflix, η αξία τους αποτυπώνεται κυρίως στην αύξηση του engagement, στη μείωση του churn και στην εξοικονόμηση κόστους. Μέσα από την αύξηση των εσόδων, την ενίσχυση της δέσμευσης των χρηστών και τη βελτίωση της συνολικής εμπειρίας, τα συστήματα συστάσεων αποτελούν βασικό παράγοντα επιτυχίας στο σύγχρονο ψηφιακό επιχειρηματικό περιβάλλον.

5.5.Σύνοψη και Ανάλυση Επιτυχίας

Η μελέτη των περιπτώσεων της Amazon και του Netflix καταδεικνύει με σαφήνεια ότι τα συστήματα συστάσεων αποτελούν κρίσιμο παράγοντα επιτυχίας στο σύγχρονο ψηφιακό επιχειρηματικό περιβάλλον. Παρά τις διαφοροποιήσεις τους ως προς το αντικείμενο δραστηριότητας, καθώς η Amazon δραστηριοποιείται κυρίως στο ηλεκτρονικό εμπόριο ενώ το Netflix στον χώρο του streaming ψυχαγωγίας, και παρά τις διαφορές στο επιχειρηματικό τους μοντέλο, δηλαδή συναλλαγές έναντι συνδρομών, και οι δύο εταιρείες έχουν ενσωματώσει την προσωποποίηση στον πυρήνα της λειτουργίας τους.

Η στρατηγική αξιοποίηση των recommender systems επιτρέπει στις δύο επιχειρήσεις να βελτιώνουν την εμπειρία χρήστη, να αυξάνουν τη δέσμευση και να δημιουργούν σημαντική επιχειρησιακή αξία. Μια συνοπτική σύγκριση των δύο επιχειρήσεων παρουσιάζεται στον Πίνακα 5.3.

Κριτήριο	Amazon	Netflix
Κύριος στόχος RS	Αύξηση πωλήσεων & μέσου καλαθιού	Αύξηση engagement & μείωση churn
Βασική τεχνική	Item-based collaborative filtering	Υβριδικά μοντέλα + deep learning
Κύριο πλεονέκτημα	Άμεση σύνδεση με έσοδα	Δυναμική προσαρμογή σε πραγματικό χρόνο
Κύρια πρόκληση	Τεράστιος κατάλογος (εκατομμύρια SKU)	Δυναμικές προτιμήσεις, τεράστιος όγκος δεδομένων

Μετρήσιμο αποτέλεσμα	35% εσόδων από RS	80% περιεχομένου από RS

Πίνακας 5. 3 Συγκριτική ανάλυση επιτυχίας Amazon – Netflix

Πέρα από τις επιμέρους διαφορές, η επιτυχία και των δύο εντοπίζεται σε κοινούς, θεμελιώδεις παράγοντες που ξεπερνούν την απλή τεχνολογική υπεροχή. Κατ' αρχάς, η θεμελιώδης διαφοροποίησή τους δεν βρίσκεται μόνο στην υιοθέτηση υβριδικών μοντέλων, αλλά στην κουλτούρα τους να αντιμετωπίζουν κάθε αλληλεπίδραση ως μια ευκαιρία για μάθηση και στρατηγική πληροφόρηση. Και οι δύο εταιρείες έχουν θεσμοθετήσει μια διαδικασία συνεχούς ανατροφοδότησης, όπου τεχνικές όπως το online learning και το A/B testing δεν είναι απλά εργαλεία βελτιστοποίησης, αλλά ο μηχανισμός μέσω του οποίου η πλατφόρμα εξελίσσεται διαρκώς. Αυτό διασφαλίζει ότι τα συστήματά τους δεν μένουν ποτέ στατικά, αλλά προσαρμόζονται άμεσα στη δυναμική συμπεριφορά των χρηστών, μετατρέποντας τα δεδομένα από απλό καύσιμο του αλγορίθμου σε πυξίδα για στρατηγικές αποφάσεις (Jannach & Jugovac, 2019).

Εξίσου κρίσιμη είναι η συνειδητή αποφυγή της παγίδας της υπερ-εξειδίκευσης. Η ανάλυση των δύο περιπτώσεων ανέδειξε ότι η υπερβολική ακρίβεια μπορεί να γίνει πρόβλημα και να οδηγήσει σε μια φτωχή, επαναλαμβανόμενη εμπειρία. Η επιτυχία της Amazon και του Netflix βρίσκεται στο ότι αναγνωρίζουν αυτόν τον κίνδυνο και χρησιμοποιούν ενεργά μηχανισμούς διαφοροποίησης, όπως μια τυχαία πρόταση, μια ενότητα με τάσεις, ένα προϊόν από τη "μακρά ουρά" που δεν θα έβρισκε ο χρήστης μόνος του, που διατηρούν την εμπειρία φρέσκια και ενθαρρύνουν την ανακάλυψη. Το τρίτο και ίσως σημαντικότερο συμπέρασμα είναι πως η τεχνολογική υπεροχή, από μόνη της, δεν αρκεί. Και οι δύο πλατφόρμες αντιμετωπίζουν τα RS όχι ως ένα τεχνικό πρόβλημα προς επίλυση, αλλά ως ένα εργαλείο διαμόρφωσης μιας ανώτερης εμπειρίας χρήστη. Αυτό σημαίνει πως σχεδιάζουν τα συστήματά τους με γνώμονα το πώς θα νιώσει ο χρήστης, αν θα το βρει χρήσιμο, αν θα το εμπιστευτεί, αν θα νιώσει ότι τον βοηθάει ή ότι τον χειραγωγεί. Συμπεραίνουμε πως ο σχεδιασμός του συστήματος υποτάσσεται στην ανάγκη για διαφάνεια, έλεγχο και, τελικά, εμπιστοσύνη του χρήστη. Η τελική επιτυχία κρίνεται από το κατά πόσο ο χρήστης θέλει να νιώθει ότι το σύστημα είναι σύμμαχός του, όχι αντίπαλός του.

Τελικά, η περίπτωση της Amazon και του Netflix δείχνει ότι η πραγματική δύναμη των συστημάτων συστάσεων δεν κρύβεται απλά σε μια καλύτερη μηχανική μάθηση. Κρύβεται

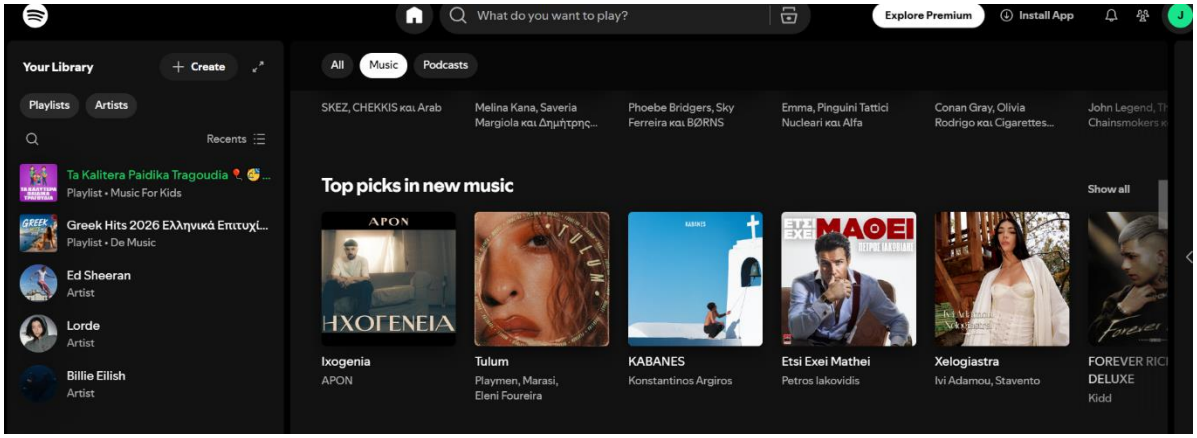
στο ότι αυτές οι εταιρείες τα έβαλαν στον πυρήνα της στρατηγικής τους. Σε ένα οικοσύστημα όπου η τεχνολογία, η στρατηγική δεδομένων και ο ανθρωποκεντρικός σχεδιασμός συνυπάρχουν αρμονικά Αυτός ο συνδυασμός τεχνολογίας, δεδομένων και προσήλωσης στον χρήστη είναι που χτίζει ένα αδιάσειστο ανταγωνιστικό πλεονέκτημα που δεν είναι εύκολο να το φτάσεις (Jannach & Jugovac, 2019). Μελλοντική έρευνα θα μπορούσε να επικυρώσει αυτά τα ευρήματα μέσω εμπειρικών μεθόδων, όπως το A/B testing, προσφέροντας μια ακόμη πιο άμεση εικόνα της αποτελεσματικότητας των διαφορετικών στρατηγικών προσωποποίησης.

6. ΚΕΦΑΛΑΙΟ 6: Μελέτη Περίπτωσης – Spotify & Tripadvisor

6.1.Εξατομίκευση στην Ψυχαγωγία και στον Τουρισμό

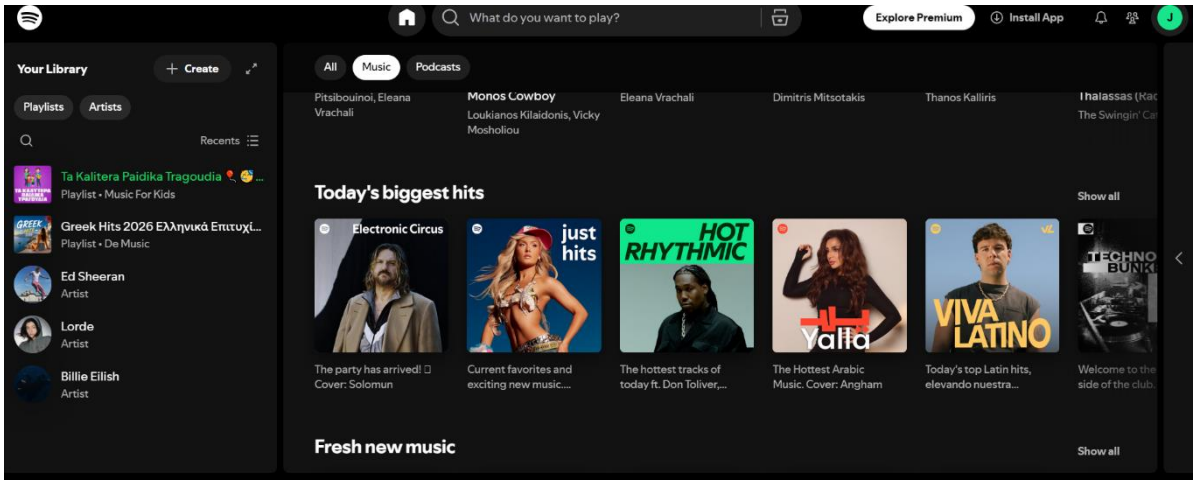
Η επιτυχία των σύγχρονων ψηφιακών πλατφορμών συχνά κρίνεται από την ικανότητά τους να προσαρμόζονται σε αντίθετες ανάγκες. Το Spotify και το Tripadvisor αποτελούν χαρακτηριστικά παραδείγματα αυτής της αρχής, καθώς καλούνται να διαχειριστούν δύο πολύ διαφορετικές μορφές κατανάλωσης: την συνεχή ροή της μουσικής και την περιστασιακή, αλλά υψηλού ρίσκου, διαδικασία σχεδιασμού ενός ταξιδιού. Παρότι οι κλάδοι τους είναι εντελώς διαφορετικοί, και οι δύο βασίζονται στη συστηματική ανάλυση δεδομένων για να μετατρέψουν μια δυνητικά χαοτική πληθώρα επιλογών σε μια απλή, προσωπική εμπειρία.
Τα RS εδώ αξιοποιούνται με σκοπό τη δημιουργία εξατομικευμένων εμπειριών, προσαρμοσμένων στις ανάγκες, τα ενδιαφέροντα και τη συμπεριφορά των χρηστών.
Αναφορικά με το περιβάλλον του Spotify, η εξατομίκευση αποτελεί έναν από τους βασικούς πυλώνες της πλατφόρμας. Η υπηρεσία καλείται να διαχειριστεί έναν εξαιρετικά μεγάλο όγκο μουσικού περιεχομένου ο οποίος ήδη από το 2022 ξεπερνούσε τα 100 εκατομμύρια τραγούδια (The Ledger, 2023). Μέσα σε ένα τόσο εκτεταμένο περιβάλλον επιλογών, τα συστήματα συστάσεων βοηθούν τον χρήστη να εντοπίσει μουσική που ανταποκρίνεται στις προτιμήσεις του, χωρίς να χρειάζεται να αναζητά ενεργά μέσα σε έναν τεράστιο κατάλογο.
Η πλατφόρμα αξιοποιεί δεδομένα ακρόασης, όπως τα τραγούδια που επιλέγει ο χρήστης, τη συχνότητα ακρόασης, τις λίστες αναπαραγωγής που δημιουργεί, τις παραλείψεις τραγουδιών (skips), τις επαναλήψεις και τις αποθηκεύσεις στη βιβλιοθήκη. Με βάση αυτά τα δεδομένα, το σύστημα δημιουργεί δυναμικά προφίλ προτιμήσεων, τα οποία ενημερώνονται συνεχώς όσο ο χρήστης αλληλεπιδρά με την πλατφόρμα.
Σύμφωνα με τους Jannach και Jugovac (2019), η αξιοποίηση τέτοιων δεδομένων επιτρέπει την παραγωγή εξατομικευμένων προτάσεων, όπως το Discover Weekly, που προσφέρει εβδομαδιαίες προτάσεις νέας μουσικής, το Release Radar, που παρουσιάζει νέες κυκλοφορίες από αγαπημένους ή συναφείς καλλιτέχνες, τα Daily Mixes, τα οποία οργανώνουν τραγούδια με βάση είδη, διαθέσεις ή προηγούμενες ακροάσεις, καθώς και το AI DJ, που παρέχει μια πιο διαδραστική και προσωποποιημένη εμπειρία ακρόασης.
Η συνεχής ανανέωση αυτών των προτάσεων ενισχύει τη δέσμευση του χρήστη και συμβάλλει στην αύξηση του χρόνου χρήσης της πλατφόρμας. Με αυτόν τον τρόπο, το Spotify δεν

λειτουργεί μόνο ως χώρος πρόσβασης σε μουσικό περιεχόμενο, αλλά και ως μηχανισμός ανακάλυψης νέων επιλογών, προσαρμοσμένων στο προσωπικό μουσικό προφίλ κάθε χρήστη. Οι Εικόνες 6.1. 6.2, 6.3, 6.4, 6.5 παρουσιάζουν ενδεικτικά τις εξατομικευμένες λίστες της πλατφόρμας, η οποία δημιουργεί δυναμικές προτάσεις όπως τα «Top picks in new music» και «Today's biggest hits» (νέες ανακαλύψεις), τα «More of what you like» και «Your artists mixes» (νέες κυκλοφορίες από αγαπημένους καλλιτέχνες) και το «Recommended for today» (εξατομικευμένες λίστες βάση πρόσφατης δραστηριότητας προφίλ).



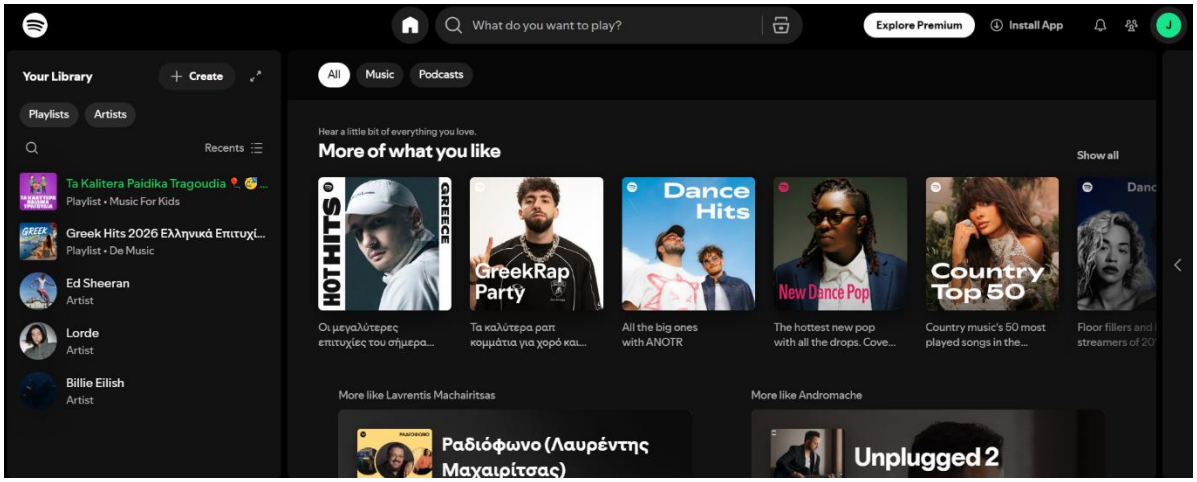
Εικόνα 6. 1

«Top picks in new music» Λίστα Προτάσεων για νέα Μουσική, Βάσει προτιμώμενων καλλιτεχνών *Πηγή: Spotify (screenshot από τον συγγραφέα,Μάιος 2026)*



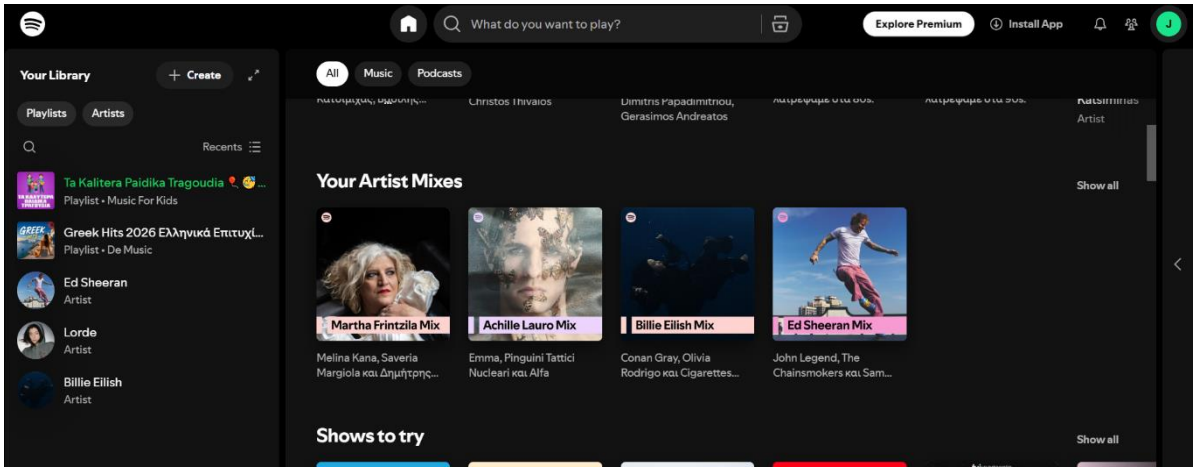
Εικόνα 6. 2

«Today's biggest hits» Λίστα Προτάσεων με νέες κυκλοφορίες με παγκόσμια απήχης, χωρίς απαραίτητα να έχουν σχέση με το προφίλ του χρήστη *Πηγή: Spotify (screenshot από τον συγγραφέα,Μάιος 2026)*



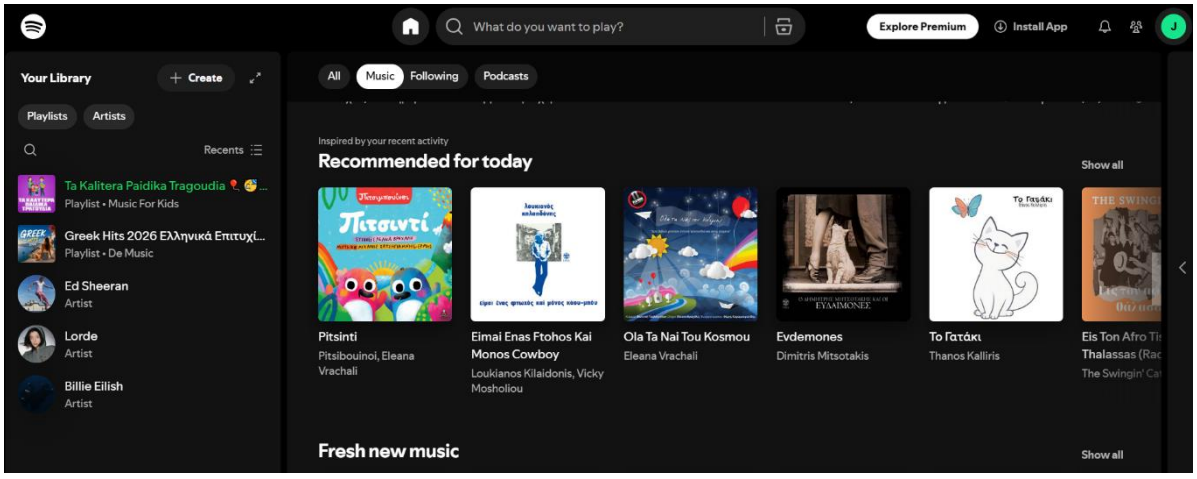
Εικόνα 6. 3

«More of what you like» Λίστα Προτάσεων για κυκλοφορίες από αγαπημένους καλλιτέχνες *Πηγή: Spotify (screenshot από τον συγγραφέα,Μάιος 2026)*



Εικόνα 6. 4

«Your artists mixes» Λίστα Προτάσεων για κυκλοφορίες από αγαπημένους καλλιτέχνες *Πηγή: Spotify (screenshot από τον συγγραφέα,Μάιος 2026)*

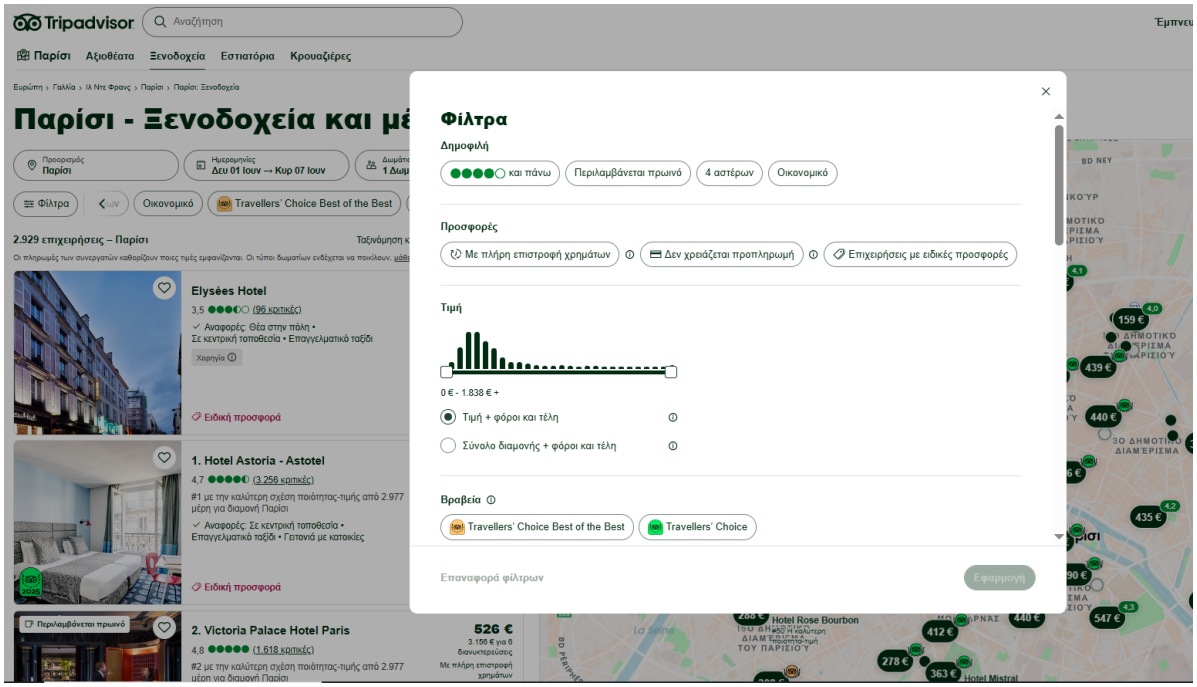


Εικόνα 6. 5

«Recommended for today» Λίστα Προτάσεων, εξατομικευμένη βάσει πρόσφατης δραστηριότητας προφιλ. *Πηγή: Spotify (screenshot από τον συγγραφέα,Μάιος 2026)*

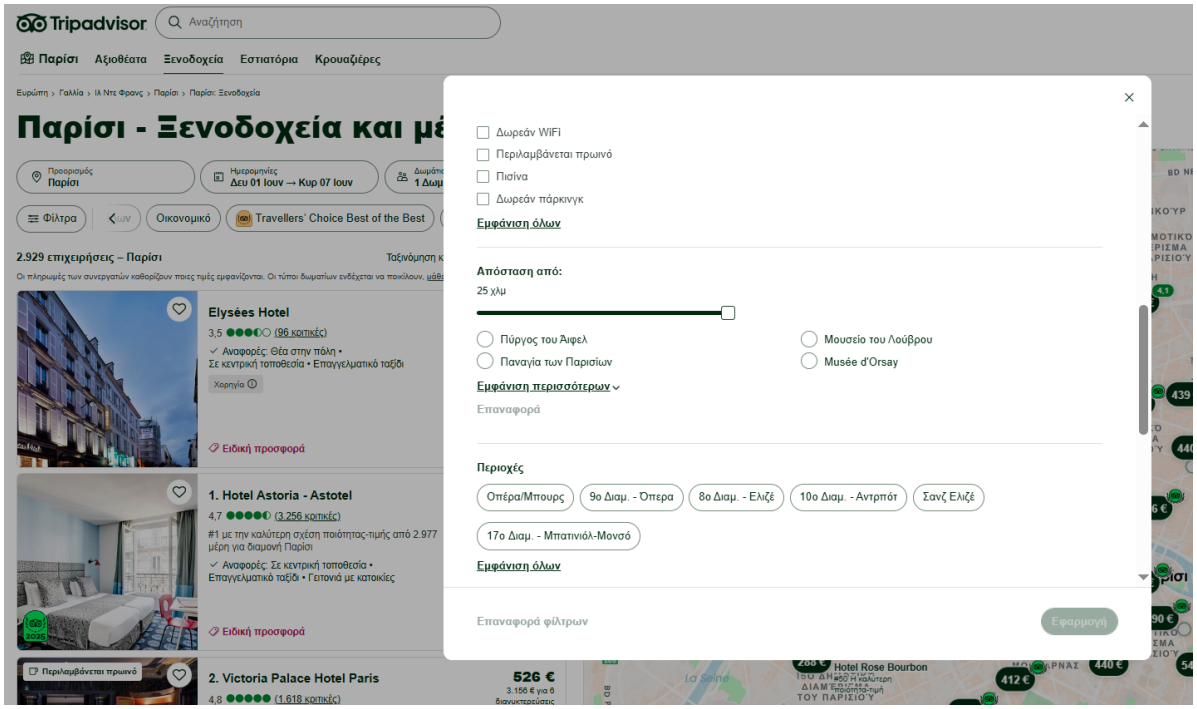
Αντίστοιχα, στην περίπτωση του Tripadvisor, η εξατομίκευση εφαρμόζεται στο πλαίσιο της αναζήτησης και επιλογής τουριστικών υπηρεσιών. Η πλατφόρμα υποστηρίζει τον χρήστη στην επιλογή ξενοδοχείων, εστιατορίων, αξιοθέατων και δραστηριοτήτων, μέσα από έναν ιδιαίτερα μεγάλο όγκο διαθέσιμων πληροφοριών και αξιολογήσεων.

Όπως αναφέρουν οι Panagiotakis et al. (2022), το Tripadvisor αξιοποιεί πολλαπλές πηγές δεδομένων για την παραγωγή συστάσεων. Σε αυτές περιλαμβάνονται οι αξιολογήσεις των χρηστών, τόσο με τη μορφή βαθμολογιών όσο και με τη μορφή γραπτών σχολίων, οι δηλωμένες ή έμμεσες προτιμήσεις, όπως ο προϋπολογισμός και ο τύπος διαμονής, το ιστορικό αναζητήσεων, οι γεωγραφικές πληροφορίες, όπως η τοποθεσία του χρήστη και ο προορισμός, καθώς και παράγοντες εποχικότητας, όπως η διάκριση μεταξύ χειμερινών και καλοκαιρινών προορισμών. Η χρήση συστημάτων συστάσεων επιτρέπει στην πλατφόρμα να φιλτράρει τον τεράστιο όγκο διαθέσιμων πληροφοριών και να διευκολύνει τη διαδικασία λήψης αποφάσεων. Αυτό είναι ιδιαίτερα σημαντικό στον τουρισμό, όπου οι επιλογές είναι πολλές, συχνά ετερογενείς και δύσκολα συγκρίσιμες μεταξύ τους. Με αυτόν τον τρόπο, το Tripadvisor μπορεί να προσφέρει πιο σχετικές και χρήσιμες προτάσεις, προσαρμοσμένες στις ανάγκες, τις προτιμήσεις και το πλαίσιο του κάθε ταξιδιώτη. Οι Εικόνες 6.6, 6.7, 6.8, 6.9, και 6.10 απεικονίζουν παραδείγματα προτάσεων και αξιολογήσεων στην πλατφόρμα. Οι χρήστες μπορούν να δουν βαθμολογίες, αριθμό κριτικών, φωτογραφίες και εξατομικευμένες προτάσεις με βάση την τοποθεσία, τις προτιμήσεις και το ιστορικό αναζητήσεων.



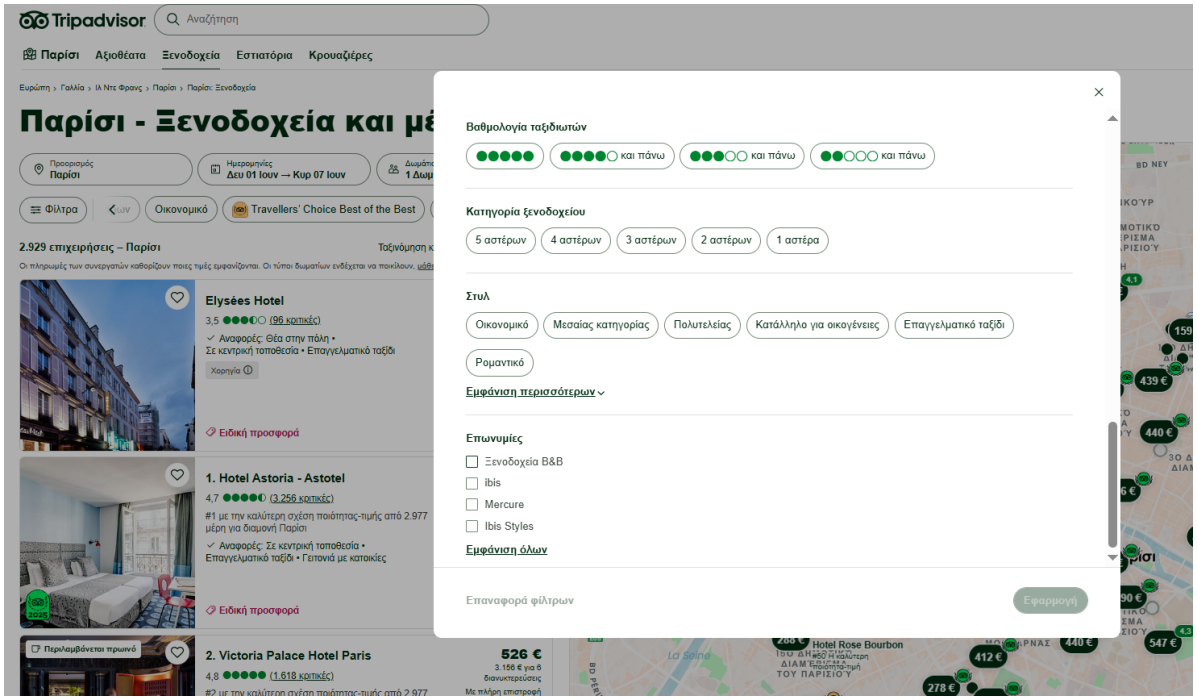
Εικόνα 6. 6

Λίστα προτάσεων βάσει προτιμώμενου προορισμού χρήστη και χρήση Φίλτρων, όπως προσφορές και τιμή, για βέλτιστη επιλογή. *Πηγή: Tripadvisor (screenshot από τον συγγραφέα, Μάιος 2026)*



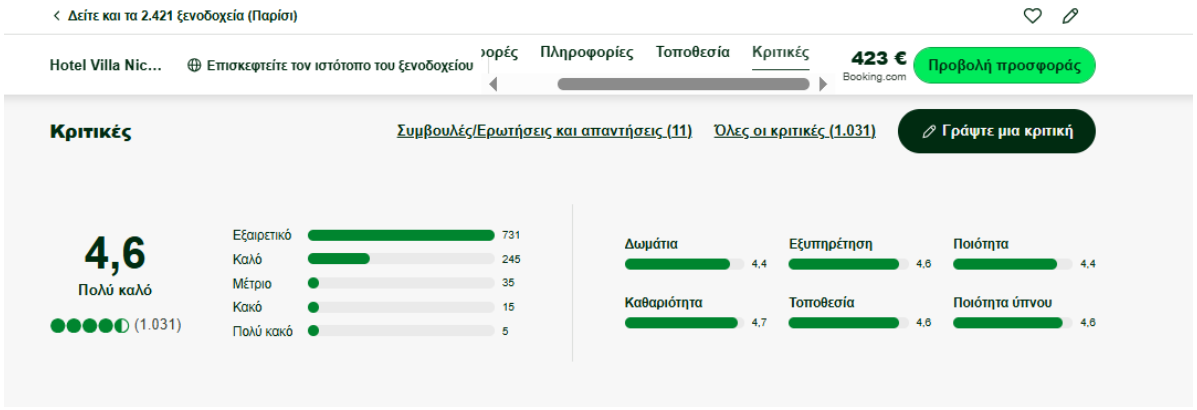
Εικόνα 6. 7

Λίστα προτάσεων βάσει προτιμώμενου προορισμού χρήστη και χρήση Φίλτρων, όπως απόσταση από διάσημα αξιοθέατα και προτιμώμενη περιοχή, για βέλτιστη επιλογή. *Πηγή: Tripadvisor (screenshot από τον συγγραφέα,Μάιος 2026)*



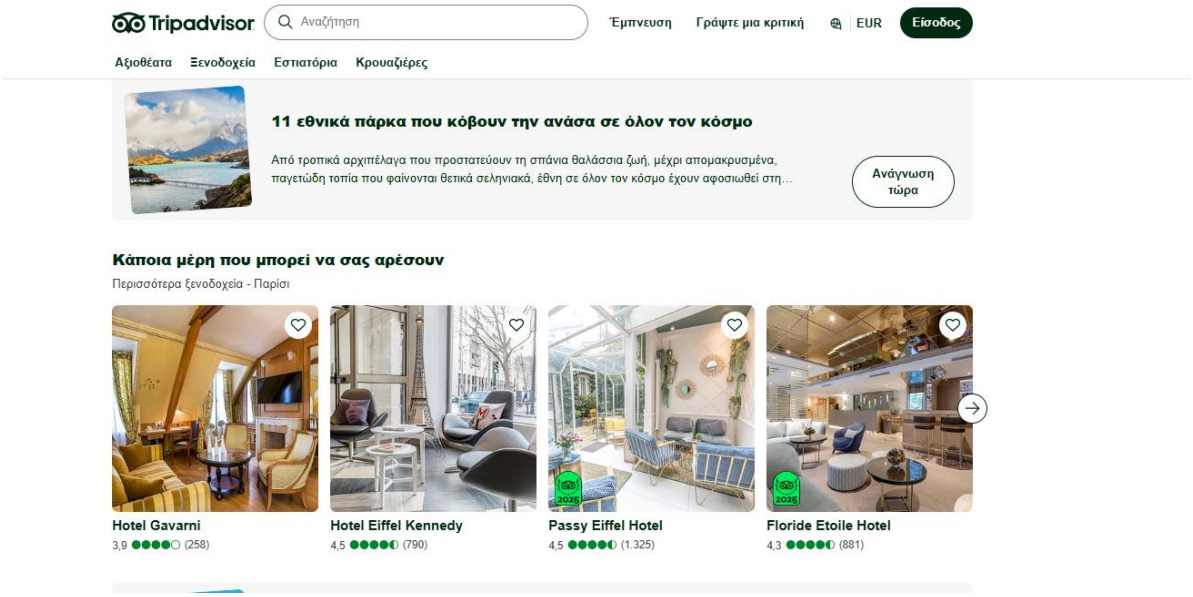
Εικόνα 6. 8

Λίστα προτάσεων βάσει προτιμώμενου προορισμού χρήστη και χρήση Φίλτρων, όπως βαθμολογία προηγούμενων πελατών και είδος στυλ του γρουπ των ταξιδιωτών, για βέλτιστη επιλογή. *Πηγή: Tripadvisor (screenshot από τον συγγραφέα, Μάιος 2026)*



Εικόνα 6. 9

Χρήση Φίλτρου Κριτικές για βέλτιστη επιλογή. *Πηγή: Tripadvisor (screenshot από τον συγγραφέα, Μάιος 2026)*



Εικόνα 6. 10

Λίστα προτάσεων βάσει προτιμώμενου προορισμού και βάσει ιστορικού Αναζήτησης χρήστη για βέλτιστη επιλογή. *Πηγή: Tripadvisor (screenshot από τον συγγραφέα, Μάιος 2026)*

Αν και οι δύο πλατφόρμες βασίζονται στην ίδια λογική της ανάλυσης δεδομένων, το κάνουν για να εξυπηρετήσουν ριζικά διαφορετικές ανάγκες. Το Spotify έχει σχεδιαστεί για να κρατά τον χρήστη σε μια συνεχή, σχεδόν αβίαστη ροή ανακάλυψης. Οι προτάσεις του δεν χρειάζεται να είναι απόλυτα ακριβείς, αρκεί να είναι αρκετά σχετικές ώστε ο χρήστης να συνεχίσει να ακούει. Το Tripadvisor, από την άλλη, καλείται να υποστηρίξει μια απόφαση με συνέπειες όπως την επιλογή ενός ξενοδοχείου ή ενός εστιατορίου. Εδώ, ο χρήστης δεν δέχεται απλώς το περιεχόμενο αλλά συγκρίνει, αξιολογεί και θέλει να νιώσει σιγουριά πριν κάνει κράτηση. Γι' αυτό και οι προτάσεις του συνδυάζουν πολλά φίλτρα ταυτόχρονα, από την τιμή και την τοποθεσία μέχρι τις κριτικές άλλων ταξιδιωτών, με σκοπό να οδηγήσουν σε μια τεκμηριωμένη, και όχι απλώς γρήγορη, απόφαση.

Η εξατομίκευση στον τουρισμό είναι εκ φύσεως πιο σύνθετη, καθώς κάθε πρόταση επηρεάζεται από ένα πλέγμα παραγόντων. Μια οικογενειακή εκδρομή και ένα επαγγελματικό ταξίδι έχουν ελάχιστα κοινά, και το σύστημα οφείλει να το γνωρίζει αυτό (Panagiotakis et al., 2022). Στην ψυχαγωγία, από την άλλη, η πρόκληση είναι διαφορετική: το Spotify δεν χρειάζεται να μαντέψει μια τέλεια επιλογή, αλλά να κρατήσει τον χρήστη σε μια κατάσταση engagement. Αυτό σημαίνει πως μια πρόταση δεν κρίνεται τόσο από το αν είναι απόλυτα ακριβής, όσο από το αν καταφέρνει να αποτρέψει την πλήξη και το skip. Και στις δύο

περιπτώσεις, πάντως, η ουσία παραμένει ίδια, πως τα συστήματα συστάσεων δεν υπάρχουν απλώς για να προτείνουν, αλλά για να καταλαβαίνουν το πλαίσιο μέσα στο οποίο ο χρήστης παίρνει την απόφασή του.

6.2.Πώς Λειτουργούν τα Recommender Systems σε Τεχνικό Επίπεδο

Παρότι και οι δύο πλατφόρμες βασίζονται σε προηγμένες τεχνικές μηχανικής μάθησης, η τεχνική τους προσέγγιση διαφέρει σημαντικά, κυρίως λόγω της φύσης των δεδομένων που αξιοποιούν. Το Spotify καλείται να ερμηνεύσει μια συνεχή ροή από κυρίως έμμεσα σήματα (implicit feedback), ενώ το Tripadvisor βασίζεται σε πιο αραιά, αλλά πλούσια σε νόημα, ρητά δεδομένα (explicit feedback), όπως οι βαθμολογίες και οι γραπτές κριτικές (Alamdari et al., 2020).

Για το Spotify, η πρόκληση δεν είναι απλώς ο όγκος των δεδομένων, αλλά η ασάφειά τους, καθώς ένα skip μπορεί να σημαίνει «δεν μου αρέσει» ή απλώς «δεν έχω διάθεση τώρα». Για να βγάλει νόημα από αυτή την ασάφεια, η πλατφόρμα επενδύει βαθιά σε τεχνικές deep learning και embeddings (Zhang et al., 2019). Στην πράξη, κάθε χρήστης και κάθε τραγούδι αποκτούν μια διανυσματική αναπαράσταση που συμπυκνώνει τα χαρακτηριστικά τους σε έναν ενιαίο μαθηματικό χώρο. Για τα τραγούδια, αυτό μπορεί να βασίζεται στα ηχητικά τους γνωρίσματα αλλά και σε πιο αφηρημένα μοτίβα, όπως το είδος μουσικής ή η εποχή κυκλοφορίας. Για τους χρήστες, το embedding διαμορφώνεται από ολόκληρο το ιστορικό ακρόασης. Η ομοιότητα ανάμεσα σε έναν χρήστη και ένα τραγούδι υπολογίζεται με μετρικές όπως η cosine similarity, ενώ παράλληλα το σύστημα εντοπίζει χρήστες με παρόμοια πρότυπα ακρόασης μέσω collaborative filtering (Alamdari et al., 2020, Manning, Raghavan & Schütze, 2008). Τέλος, μια διαδικασία κατάταξης (ranking) ταξινομεί όλα τα υποψήφια τραγούδια με βάση την εκτιμώμενη συνάφεια, ώστε ο χρήστης να βλέπει πρώτα ό,τι έχει τις περισσότερες πιθανότητες να κρατήσει τη ροή ακρόασης ζωντανή.

Στον αντίποδα, το Tripadvisor αντιμετωπίζει μια διαφορετική πραγματικότητα, όπου οι χρήστες δεν καταναλώνουν περιεχόμενο καθημερινά, γεγονός που καθιστά τα δεδομένα αλληλεπίδρασης πιο αραιά. Ωστόσο, η πλατφόρμα διαθέτει το ισχυρό πλεονέκτημα πως η πλούσια ρητή ανατροφοδότηση με τη μορφή βαθμολογιών, γραπτών κριτικών και επιμέρους αξιολογήσεων για κριτήρια όπως η καθαριότητα, η τοποθεσία ή η σχέση ποιότητας-τιμής,

μια τεράστια δεξαμενή δεδομένων είναι στην διάθεσή της. Εδώ, το content-based filtering αξιοποιεί τεχνικές επεξεργασίας φυσικής γλώσσας (NLP) για να αναλύσει τα κείμενα των κριτικών και να εξάγει λέξεις-κλειδιά ή συναισθηματικές αποχρώσεις, χτίζοντας ένα προφίλ προτιμήσεων για τον χρήστη (π.χ. προτίμηση σε ξενοδοχεία με πισίνα ή κεντρική τοποθεσία). Παράλληλα, το collaborative filtering εντοπίζει ταξιδιώτες με παρόμοια πρότυπα αξιολογήσεων και προτείνει επιλογές που άρεσαν σε εκείνους. Αυτό που διαφοροποιεί ουσιαστικά το Tripadvisor, ωστόσο, είναι η έμφαση στις context-aware τεχνικές, καθώς μια τουριστική απόφαση δεν εξαρτάται μόνο από τις προτιμήσεις του χρήστη αλλά και από το πλαίσιο του ταξιδιού. Το σύστημα ενσωματώνει παραμέτρους όπως η γεωγραφική τοποθεσία, οι ημερομηνίες, η εποχικότητα, ο σκοπός του ταξιδιού και ο προϋπολογισμός. Για παράδειγμα, οι ανάγκες μιας οικογένειας που ταξιδεύει τον Αύγουστο διαφέρουν ριζικά από εκείνες ενός επαγγελματία που αναζητά κατάλυμα για ένα διήμερο συνέδριο, και οι προτάσεις προσαρμόζονται δυναμικά σε αυτές τις παραμέτρους (Panagiotakis et al., 2022). Τελικά, μια διαδικασία κατάταξης συνδυάζει όλα τα διαθέσιμα σήματα για να παραγάγει μια εξατομικευμένη λίστα που υποστηρίζει τον χρήστη στη λήψη μιας τεκμηριωμένης απόφασης. Ιδιαίτερο ενδιαφέρον παρουσιάζει η σύγκριση των τεχνικών προσεγγίσεων μεταξύ Spotify και Tripadvisor που παραθέτετε στον Πίνακα 6.1. Σε αυτόν παρουσιάζονται οι βασικές διαφορές ως προς τις κύριες τεχνικές που χρησιμοποιούνται, τον τύπο των δεδομένων, τη χρήση embeddings, την υποστήριξη context-aware λειτουργιών και τον τρόπο με τον οποίο πραγματοποιείται η κατάταξη των προτάσεων.

Χαρακτηριστικό	Spotify	Tripadvisor
Κύριες τεχνικές	CF + content-based + deep learning	CF + content-based + context-aware
Τύπος δεδομένων	Κυρίως implicit (ακρόαση, skips)	Explicit (αξιολογήσεις) + implicit
Embeddings	Ναι (χρήστες + τραγούδια)	Περιορισμένα (πιο δύσκολο λόγω αραιότητας)
Context-aware	Όχι (κύρια εστίαση σε προτιμήσεις)	Ναι (τοποθεσία, ημερομηνίες, σκοπός)
Ranking	Βάσει πιθανότητας επόμενης ακρόασης	Βάσει πολυκριτηριακής βαθμολογίας

Πίνακας 6. 1 Σύγκριση των τεχνικών προσεγγίσεων μεταξύ Spotify και Tripadvisor

Αυτό που αποκαλύπτει ο πίνακας είναι δύο θεμελιωδώς διαφορετικές φιλοσοφίες σχεδιασμού. Το Spotify, έχοντας την πολυτέλεια της αφθονίας δεδομένων αλλά την πρόκληση της ασάφειας, επενδύει σε προηγμένα μοντέλα βαθιάς μάθησης και embeddings για να «ακούσει» πίσω από τον θόρυβο των καθημερινών συνηθειών. Το Tripadvisor, από την άλλη, διαθέτει πιο ξεκάθαρα αλλά και πιο αραιά δεδομένα. Γι' αυτό και στρέφεται σε context-aware τεχνικές, εφόσον όταν ξέρεις ήδη τι άρεσε στον χρήστη, το ζητούμενο είναι να καταλάβεις σε ποιο πλαίσιο θα το χρησιμοποιήσει. Με λίγα λόγια, το Spotify προσπαθεί να μαντέψει το γούστο, ενώ το Tripadvisor προσπαθεί να μαντέψει την περίσταση.

Θα άξιζε όμως ν' αναρωτηθεί κανείς και για τα κοινά τους σημεία. Αρχικά, και οι δύο πλατφόρμες αξιοποιούν μηχανισμούς κατάταξης (ranking), οι οποίοι συνδυάζουν πολλαπλά σήματα για την παραγωγή των τελικών προτάσεων. Τα σήματα αυτά μπορεί να σχετίζονται με τη συμπεριφορά του χρήστη, τα χαρακτηριστικά του περιεχομένου ή της υπηρεσίας, καθώς και με το ευρύτερο πλαίσιο χρήσης. Παράλληλα, τόσο το Spotify όσο και το Tripadvisor βασίζονται στη συνεχή ενημέρωση των μοντέλων τους με νέα δεδομένα, ώστε οι προτάσεις να παραμένουν επίκαιρες και σχετικές. Η δυναμική προσαρμογή των αποτελεσμάτων αποτελεί βασικό στοιχείο της λειτουργίας τους, καθώς επιτρέπει στα συστήματα να ανταποκρίνονται στις μεταβαλλόμενες προτιμήσεις και ανάγκες των χρηστών.

Με δύο λόγια, το Spotify και το Tripadvisor απαντούν στο ίδιο ερώτημα, το οποίο είναι «τι να προτείνω τώρα;» αλλά με εντελώς διαφορετικά εργαλεία, προσαρμοσμένα το καθένα στη δική του πραγματικότητα δεδομένων.

6.3.Εμπειρία Χρήστη και Στρατηγική Engagement

Η εμπειρία χρήστη (User Experience – UX) και η ενίσχυση της δέσμευσης (engagement) αποτελούν βασικούς άξονες λειτουργίας τόσο για το Spotify όσο και για το Tripadvisor. Στο πλαίσιο αυτό, τα συστήματα συστάσεων διαδραματίζουν καθοριστικό ρόλο, καθώς επιτρέπουν την παροχή εξατομικευμένου περιεχομένου και τη συνεχή προσαρμογή της πλατφόρμας στις προτιμήσεις των χρηστών (Pu et al., 2012).

Στην περίπτωση του Spotify, η στρατηγική engagement βασίζεται κυρίως στην ενίσχυση της αλληλεπίδρασης μέσα από μια συνεχή και απρόσκοπτη ροή περιεχομένου. Η λειτουργία της αυτόματης αναπαραγωγής (autoplay), για παράδειγμα, επιτρέπει στο σύστημα να προτείνει άμεσα το επόμενο τραγούδι ή σχετικό περιεχόμενο μετά το τέλος μιας λίστας ή ενός

κομματιού. Με αυτόν τον τρόπο, μειώνεται η ανάγκη ενεργής αναζήτησης από τον χρήστη και ενισχύεται η συνεχής ακρόαση. Ένα ακόμη βασικό στοιχείο είναι η τακτική ανανέωση των προτάσεων. Λειτουργίες όπως το Discover Weekly, που ανανεώνεται κάθε Δευτέρα, το Release Radar, που ενημερώνεται κάθε Παρασκευή, και τα Daily Mixes, που προσαρμόζονται καθημερινά, δημιουργούν μια αίσθηση προσδοκίας και συνήθειας. Ο χρήστης επιστρέφει στην πλατφόρμα όχι μόνο για να ακούσει γνωστό περιεχόμενο, αλλά και για να ανακαλύψει τι νέο του προτείνει το σύστημα.

Παράλληλα, η εμπειρία χρήσης στο Spotify χαρακτηρίζεται από αμεσότητα και ροή (seamless experience). Η μετάβαση από το ένα τραγούδι στο επόμενο γίνεται χωρίς διακοπές, ενώ ο χρήστης δεν χρειάζεται να αποφασίζει συνεχώς τι θα ακούσει στη συνέχεια. Αυτό συμβάλλει στην αύξηση του χρόνου παραμονής στην πλατφόρμα και στη συνολική ενίσχυση της δέσμευσης (Jannach & Jugovac, 2019).

Σημαντικό ρόλο παίζουν και οι μηχανισμοί ανατροφοδότησης. Ενέργειες όπως το like ή το dislike αποτελούν μορφές ρητής ανατροφοδότησης, ενώ το skip λειτουργεί ως έμμεσο σήμα αρνητικής προτίμησης. Αντίστοιχα, η αποθήκευση ενός τραγουδιού στη βιβλιοθήκη αποτελεί ισχυρό θετικό σήμα. Οι πληροφορίες αυτές ενημερώνουν άμεσα το μοντέλο, επιτρέποντας στο σύστημα να προσαρμόζεται δυναμικά στις προτιμήσεις του χρήστη.

Παρόλα αυτά, η εξατομίκευση στο Spotify δεν λειτουργεί με τρόπο καταναγκαστικό. Ο χρήστης διατηρεί την αίσθηση ελέγχου, καθώς μπορεί ανά πάσα στιγμή να αλλάξει τραγούδι, να δημιουργήσει δικές του λίστες ή να αναζητήσει περιεχόμενο ανεξάρτητα από τις προτάσεις της πλατφόρμας. Η ισορροπία αυτή ανάμεσα στην αυτοματοποιημένη πρόταση και στην προσωπική επιλογή ενισχύει τη συνολική εμπειρία χρήστη. Η Εικόνα 6.1 παρουσιάζει ενδεικτικά την εξατομίκευση της πλατφόρμας.

Στην περίπτωση του Tripadvisor, η εμπειρία χρήστη έχει διαφορετική φύση. Οι χρήστες δεν βρίσκονται απαραίτητα συνεχώς στην πλατφόρμα, όπως συμβαίνει σε μια υπηρεσία μουσικής, αλλά την επισκέπτονται συνήθως περιστασιακά, κυρίως πριν ή κατά τη διάρκεια ενός ταξιδιού. Επιπλέον, οι αποφάσεις που λαμβάνονται μέσω της πλατφόρμας έχουν συχνά μεγαλύτερη σημασία, καθώς συνδέονται με χρήματα, χρόνο, προσδοκίες και την ποιότητα της ταξιδιωτικής εμπειρίας. Σημαντική είναι επίσης η κοινωνική διάσταση, καθώς οι αξιολογήσεις και οι εμπειρίες άλλων χρηστών επηρεάζουν ουσιαστικά τη διαδικασία επιλογής. Όπως αναφέρουν οι Xiao και Benbasat (2007), ένα βασικό χαρακτηριστικό της πλατφόρμας είναι η οργάνωση της πληροφορίας. Τα συστήματα συστάσεων βοηθούν στο

φιλτράρισμα χιλιάδων επιλογών, όπως ξενοδοχεία, εστιατόρια και δραστηριότητες, και παρουσιάζουν εξατομικευμένες λίστες με βάση τις προτιμήσεις του χρήστη, την τοποθεσία και τον διαθέσιμο προϋπολογισμό. Παράλληλα, το Tripadvisor υποστηρίζει τη δυνατότητα σύγκρισης μεταξύ διαφορετικών επιλογών. Ο χρήστης μπορεί να εξετάσει πολλαπλές εναλλακτικές, να συγκρίνει βαθμολογίες, αριθμό κριτικών, επιμέρους σκορ, φωτογραφίες και αναλυτικά σχόλια. Η δυνατότητα αυτή ενισχύει τη διαφάνεια και βοηθά τον χρήστη να λάβει πιο τεκμηριωμένες αποφάσεις.

Ιδιαίτερα σημαντική είναι η έννοια της κοινωνικής απόδειξης (social proof). Οι προτάσεις δεν βασίζονται μόνο σε αλγοριθμική επεξεργασία, αλλά και σε πραγματικές εμπειρίες άλλων ταξιδιωτών. Όταν ένας χρήστης βλέπει ότι μια επιχείρηση έχει υψηλή βαθμολογία και μεγάλο αριθμό αξιολογήσεων, ενισχύεται η εμπιστοσύνη του προς την επιλογή αυτή. Η κοινωνική αυτή διάσταση αποτελεί βασικό παράγοντα αξιοπιστίας για την πλατφόρμα (Xiao & Benbasat, 2007).

Επιπλέον, η ενεργή συμμετοχή της κοινότητας συμβάλλει στη διαρκή ανανέωση και βελτίωση της πληροφορίας. Οι χρήστες προσθέτουν αξιολογήσεις, φωτογραφίες και σχόλια, δημιουργώντας ένα δυναμικό οικοσύστημα πληροφορίας. Όσο περισσότερες αξιολογήσεις συγκεντρώνονται, τόσο περισσότερα δεδομένα διαθέτει το σύστημα για την παραγωγή καλύτερων και πιο αξιόπιστων προτάσεων.

Τέλος, τα συστήματα συστάσεων συμβάλλουν στη μείωση της γνωστικής επιβάρυνσης (cognitive load). Αντί ο χρήστης να χρειάζεται να διαβάσει εκατοντάδες κριτικές ή να συγκρίνει χειροκίνητα μεγάλο αριθμό επιλογών, μπορεί να βασιστεί σε συνοπτικές βαθμολογίες, φίλτρα και εξατομικευμένες προτάσεις. Με αυτόν τον τρόπο, η διαδικασία επιλογής γίνεται ταχύτερη, πιο οργανωμένη και λιγότερο αγχωτική. Η Εικόνα 6.2 απεικονίζει ένα παράδειγμα προτάσεων και αξιολογήσεων.

Σύγκριση στρατηγικών engagement

Οι διαφορές στις στρατηγικές engagement μεταξύ Spotify και Tripadvisor συνοψίζονται στον Πίνακα 6.2. Σε αυτόν παρουσιάζονται βασικές παράμετροι σύγκρισης, όπως η φύση της χρήσης, ο κύριος στόχος κάθε πλατφόρμας, ο τύπος ανατροφοδότησης, η κοινωνική διάσταση και οι πιθανοί κίνδυνοι που σχετίζονται με την εμπειρία χρήστη.

Χαρακτηριστικό	Spotify	Tripadvisor
Φύση χρήσης	Συνεχής ροή (καθημερινή)	Περιστασιακή (πριν από ταξίδι)
Κύριος στόχος	Αύξηση χρόνου ακρόασης	Υποστήριξη απόφασης + εμπιστοσύνη
Τύπος ανατροφοδότησης	Implicit (skips) + explicit (likes)	Explicit (αξιολογήσεις, κριτικές)
Κοινωνική διάσταση	Περιορισμένη (κοινές λίστες)	Ισχυρή (κριτικές, βαθμολογίες)
Κίνδυνος	Υπερ-εξάρτηση από προτάσεις	Παραπληροφόρηση (ψεύτικες κριτικές)

Πίνακας 6. 2 Σύγκριση στρατηγικών engagement μεταξύ Spotify και Tripadvisor

Κοινές προκλήσεις

Παρά τις διαφορές στη φύση και στον τρόπο χρήσης των δύο πλατφορμών, τόσο το Spotify όσο και το Tripadvisor αντιμετωπίζουν ορισμένες κοινές προκλήσεις που συνδέονται με τη λειτουργία των συστημάτων συστάσεων.

Μία από τις σημαντικότερες είναι η υπερ-εξειδίκευση (over-specialization). Το φαινόμενο αυτό εμφανίζεται όταν ο χρήστης εκτίθεται συνεχώς σε παρόμοιο περιεχόμενο ή σε παρόμοιες προτάσεις, με αποτέλεσμα να περιορίζεται η δυνατότητα εξερεύνησης νέων επιλογών. Για την αντιμετώπιση αυτού του κινδύνου, οι πλατφόρμες μπορούν να ενσωματώνουν τυχαίες ή λιγότερο αναμενόμενες προτάσεις, καθώς και ειδικές ενότητες ανακάλυψης, όπως για παράδειγμα λειτουργίες τύπου «Explore».

Μια δεύτερη πρόκληση είναι το φαινόμενο του filter bubble. Σε αυτή την περίπτωση, ο χρήστης εγκλωβίζεται σε ένα περιβάλλον που επιβεβαιώνει συνεχώς τις ήδη υπάρχουσες προτιμήσεις του, χωρίς να εκτίθεται επαρκώς σε διαφορετικά είδη, απόψεις, εμπειρίες ή επιλογές. Το φαινόμενο αυτό μπορεί να περιορίσει τη διαφορετικότητα των προτάσεων και να μειώσει τη συνολική αξία της εξατομίκευσης.

Επιπλέον, σημαντικό ζήτημα αποτελεί και η κούραση από τις προτάσεις. Όταν οι συστάσεις είναι υπερβολικά συχνές, επαναλαμβανόμενες ή προβλέψιμες, ο χρήστης μπορεί σταδιακά να αρχίσει να τις αγνοεί. Για τον λόγο αυτό, απαιτείται συνεχής ανανέωση των αλγορίθμων,

εμπλουτισμός των προτάσεων με στοιχεία καινοτομίας (novelty) και προσεκτική ισορροπία ανάμεσα στη συνάφεια και την ποικιλία.

Καταλήγοντας, η εμπειρία χρήστη και η στρατηγική engagement στο Spotify και στο Tripadvisor διαμορφώνονται σε μεγάλο βαθμό από τα συστήματα συστάσεων. Το Spotify εστιάζει κυρίως στη συνεχή ροή περιεχομένου, στην ανακάλυψη νέας μουσικής και στη δημιουργία συνήθειας χρήσης. Αντίθετα, το Tripadvisor δίνει μεγαλύτερη έμφαση στην υποστήριξη της απόφασης, στην κοινωνική εμπιστοσύνη και στη μείωση της γνωστικής επιβάρυνσης κατά την επιλογή τουριστικών υπηρεσιών.

Η αποτελεσματική αξιοποίηση των recommender systems επιτρέπει τη δημιουργία δυναμικών, προσωποποιημένων και ελκυστικών ψηφιακών περιβαλλόντων. Με αυτόν τον τρόπο, ενισχύεται η δέσμευση των χρηστών και υποστηρίζεται η βιωσιμότητα των αντίστοιχων επιχειρηματικών μοντέλων.

6.4. Ανάλυση Πλεονεκτημάτων και Προκλήσεων

Η αξιοποίηση των συστημάτων συστάσεων στο Spotify και στο Tripadvisor προσφέρει σημαντικά πλεονεκτήματα, αλλά συνοδεύεται και από ορισμένες ουσιαστικές προκλήσεις. Η ανάλυση που ακολουθεί εστιάζει στα στοιχεία που είναι ιδιαίτερα σημαντικά για κάθε πλατφόρμα, λαμβάνοντας υπόψη τόσο τη φύση της υπηρεσίας όσο και τον τρόπο με τον οποίο οι χρήστες αλληλεπιδρούν με αυτή.

Πλεονεκτήματα

1. Εξατομίκευση και μείωση πολυπλοκότητας

Ένα από τα βασικότερα πλεονεκτήματα των recommender systems είναι η δυνατότητα παροχής εξατομικευμένων προτάσεων, οι οποίες μειώνουν την πολυπλοκότητα της επιλογής. Στην περίπτωση του Spotify, ο χρήστης δεν χρειάζεται να αναζητά συνεχώς νέο μουσικό περιεχόμενο μέσα σε έναν τεράστιο κατάλογο τραγουδιών, καθώς η πλατφόρμα προτείνει δυναμικά κομμάτια, λίστες και καλλιτέχνες που ταιριάζουν στο μουσικό του προφίλ.

Αντίστοιχα, στο Tripadvisor, τα συστήματα συστάσεων βοηθούν τον χρήστη να περιορίσει τον μεγάλο όγκο διαθέσιμων επιλογών σε ξενοδοχεία, εστιατόρια και δραστηριότητες. Με αυτόν τον τρόπο, η διαδικασία αναζήτησης γίνεται πιο οργανωμένη και λιγότερο χρονοβόρα, ενώ ο χρήστης μπορεί να λάβει αποφάσεις με μεγαλύτερη σιγουριά και λιγότερη γνωστική επιβάρυνση.

Πλατφόρμα	Πλεονέκτημα
Spotify	Ανακάλυψη νέου μουσικού περιεχομένου που ο χρήστης πιθανότατα δεν θα έβρισκε μόνος του. Μείωση του χρόνου αναζήτησης («τι να ακούσω τώρα;»).
Tripadvisor	Διευκόλυνση επιλογής ανάμεσα σε χιλιάδες ξενοδοχεία/εστιατόρια – φιλτράρισμα βάσει προσωπικών προτιμήσεων (Pu et al., 2012).

Πίνακας 6. 3 Σύγκριση τεχνικών προσεγγίσεων (εξατομίκευση) Spotify vs Tripadvisor

2. Αύξηση δέσμευσης (engagement)

Πλατφόρμα	Πλεονέκτημα
Spotify	Αυξημένος χρόνος ακρόασης (session duration) – ο χρήστης «ροάρει» συνεχώς χωρίς να χρειάζεται να επιλέγει.
Tripadvisor	Μεγαλύτερη συμμετοχή μέσω αξιολογήσεων, κριτικών, φωτογραφιών – οι χρήστες επιστρέφουν για να συνεισφέρουν (Jannach & Jugovac, 2019).

Πίνακας 6. 4 Σύγκριση στρατηγικών engagement Spotify vs Tripadvisor

3. Αξιοποίηση δεδομένων για συνεχή βελτίωση

Ένα ακόμη σημαντικό πλεονέκτημα είναι η αξιοποίηση των δεδομένων για τη συνεχή βελτίωση των συστημάτων συστάσεων. Η συλλογή δεδομένων σε πραγματικό χρόνο επιτρέπει τη δυναμική προσαρμογή των μοντέλων, ώστε οι προτάσεις να ανταποκρίνονται πιο άμεσα στις μεταβαλλόμενες προτιμήσεις και στη συμπεριφορά των χρηστών.

Στην περίπτωση του Tripadvisor, ιδιαίτερη σημασία έχουν τα network effects. Όσο περισσότεροι χρήστες αξιολογούν ξενοδοχεία, εστιατόρια και δραστηριότητες, τόσο πλουσιότερη γίνεται η βάση δεδομένων της πλατφόρμας. Αυτό οδηγεί σε πιο αξιόπιστες και ακριβείς προτάσεις, καθώς το σύστημα μπορεί να αξιοποιεί μεγαλύτερο όγκο πραγματικών εμπειριών και αξιολογήσεων.

Προκλήσεις

1. **Υπερ-εξειδίκευση (over-specialization)**

Μία από τις βασικές προκλήσεις των συστημάτων συστάσεων είναι η υπερ-εξειδίκευση. Όπως επισημαίνεται και στην ενότητα 3.5, η αλγοριθμική ομοιομορφία μπορεί να περιορίσει την έκθεση του χρήστη σε νέες επιλογές, ενισχύοντας ήδη υπάρχουσες προτιμήσεις (Pariser, 2011).

Στην περίπτωση του Spotify, αυτό μπορεί να σημαίνει ότι ο χρήστης ακούει διαρκώς τραγούδια ίδιου ύφους, είδους ή καλλιτεχνών, γεγονός που μειώνει την πιθανότητα ανακάλυψης νέων μουσικών ειδών. Για τον περιορισμό αυτού του φαινομένου, η πλατφόρμα μπορεί να ενσωματώνει πιο τυχαίες ή απρόβλεπτες προτάσεις, όπως συμβαίνει ήδη με λειτουργίες τύπου *Discover Weekly*. Αντίστοιχα, στο Tripadvisor, η υπερ-εξειδίκευση μπορεί να οδηγήσει στην επαναλαμβανόμενη προβολή των ίδιων ξενοδοχείων, εστιατορίων ή δραστηριοτήτων, περιορίζοντας την ορατότητα εναλλακτικών επιλογών. Σε αυτή την περίπτωση, η εισαγωγή λιγότερο γνωστών ή πιο διαφοροποιημένων προτάσεων μπορεί να ενισχύσει την εμπειρία ανακάλυψης.

2. Εξάρτηση από την ποιότητα και την ποσότητα των δεδομένων

Η αποτελεσματικότητα των συστημάτων συστάσεων εξαρτάται σε μεγάλο βαθμό από την ποιότητα και την ποσότητα των διαθέσιμων δεδομένων. Στο Spotify, το πρόβλημα της ψυχρής εκκίνησης (cold start), ιδιαίτερα για νέους χρήστες, μπορεί να αντιμετωπιστεί μέσα από την αρχική δήλωση μουσικών προτιμήσεων κατά την εγγραφή, καθώς και μέσα από την αξιοποίηση δημοφιλών τραγουδιών ως σημείο εκκίνησης.

Στο Tripadvisor, αντίστοιχα, η πρόκληση σχετίζεται περισσότερο με την αραιότητα των δεδομένων (data sparsity), καθώς οι περισσότεροι χρήστες αξιολογούν σχετικά μικρό αριθμό ξενοδοχείων, εστιατορίων ή δραστηριοτήτων. Για την αντιμετώπιση αυτού του περιορισμού, η πλατφόρμα μπορεί να αξιοποιεί context-aware τεχνικές, καθώς και ανάλυση κειμένου κριτικών, ώστε να εξάγει περισσότερη πληροφορία από τα διαθέσιμα δεδομένα.

3. Ιδιωτικότητα και εμπιστοσύνη

Ζητήματα ιδιωτικότητας και εμπιστοσύνης αποτελούν επίσης σημαντική πρόκληση. Στο Spotify, η συλλογή δεδομένων ακρόασης, όπως το τι ακούει ο χρήστης, πότε το ακούει και πόσο συχνά, μπορεί να αποκαλύψει προσωπικές προτιμήσεις, συνήθειες ή ακόμη και στοιχεία της διάθεσης και της καθημερινότητάς του. Επομένως, η προστασία αυτών των δεδομένων είναι κρίσιμη για τη διατήρηση της εμπιστοσύνης των χρηστών.

Στο Tripadvisor, η εμπιστοσύνη συνδέεται σε μεγάλο βαθμό με την αξιοπιστία των αξιολογήσεων. Οι ψεύτικες κριτικές (fake reviews) μπορούν να παραπλανήσουν τους χρήστες, να επηρεάσουν αρνητικά τη διαδικασία επιλογής και να βλάψουν τη συνολική αξιοπιστία της πλατφόρμας. Για τον λόγο αυτό, απαιτούνται μηχανισμοί ανίχνευσης ψεύτικων κριτικών, καθώς και διαδικασίες επαλήθευσης χρηστών ή ταξιδιωτών, ώστε να διασφαλίζεται η ποιότητα και η αξιοπιστία της πληροφορίας (Adomavicius & Tuzhilin, 2005).

4. Τεχνική πολυπλοκότητα και κόστος

Τέλος, η τεχνική πολυπλοκότητα και το κόστος ανάπτυξης και λειτουργίας αποτελούν σημαντικούς περιορισμούς. Στην περίπτωση του Spotify, η επεξεργασία τεράστιου όγκου δεδομένων, που αφορά εκατομμύρια τραγούδια και εκατοντάδες εκατομμύρια χρήστες, απαιτεί ισχυρές υπολογιστικές υποδομές, clusters, GPUs και τεχνικές online learning.

Αντίστοιχα, στο Tripadvisor, η ανάλυση φυσικής γλώσσας (NLP) για την επεξεργασία κειμενικών κριτικών είναι υπολογιστικά απαιτητική. Επιπλέον, η ανάγκη για real-time ενημέρωση στοιχείων, όπως η διαθεσιμότητα ξενοδοχείων, οι τιμές και οι μεταβολές στη ζήτηση, αυξάνει ακόμη περισσότερο την πολυπλοκότητα του συστήματος.

Συνοπτικός πίνακας πλεονεκτημάτων και προκλήσεων

Τα βασικά σημεία σύγκρισης συνοψίζονται στον Πίνακα 6.3, όπου παρουσιάζονται τα κύρια πλεονεκτήματα και οι βασικές προκλήσεις για κάθε πλατφόρμα. Με τον τρόπο αυτό, αποτυπώνονται συνοπτικά οι διαφορές ανάμεσα στο Spotify και στο Tripadvisor, τόσο ως προς τη φύση των δεδομένων που αξιοποιούν όσο και ως προς τις απαιτήσεις και τους περιορισμούς των συστημάτων συστάσεων που εφαρμόζουν.

Κατηγορία	Spotify	Tripadvisor
Πλεονέκτημα #1	Ανακάλυψη νέας μουσικής	Φιλτράρισμα χιλιάδων επιλογών
Πλεονέκτημα #2	Αύξηση χρόνου ακρόασης	Αύξηση συμμετοχής (κριτικές)
Πρόκληση #1	Over-specialization	Over-specialization
Πρόκληση #2	Cold start (νέοι χρήστες)	Data sparsity + ψεύτικες κριτικές

Πρόκληση #3	Ιδιωτικότητα δεδομένων	Εμπιστοσύνη (fake reviews)
Πρόκληση #4	Υπολογιστικό κόστος (κλίμακα)	NLP + real-time ενημέρωση

Πίνακας 6. 5 Πλεονεκτήματα και προκλήσεις Spotify vs Tripadvisor

Συνοπτικά, η ανάλυση των πλεονεκτημάτων και των προκλήσεων των recommender systems στο Spotify και στο Tripadvisor αναδεικνύει τη διττή φύση αυτών των τεχνολογιών. Από τη μία πλευρά, τα RS προσφέρουν σημαντικά οφέλη, όπως η εξατομίκευση της εμπειρίας, η αύξηση της δέσμευσης των χρηστών και η αποτελεσματικότερη αξιοποίηση των διαθέσιμων δεδομένων. Από την άλλη πλευρά, συνοδεύονται από προκλήσεις που σχετίζονται με την υπερ-εξειδίκευση, την εξάρτηση από την ποιότητα και την ποσότητα των δεδομένων, την προστασία της ιδιωτικότητας και την τεχνική πολυπλοκότητα.

Επομένως, η αποτελεσματική αξιοποίηση των συστημάτων συστάσεων προϋποθέτει ισορροπία ανάμεσα στην ακρίβεια και την ποικιλία των προτάσεων, διαφάνεια ως προς τη χρήση των δεδομένων και συνεχή βελτιστοποίηση των αλγορίθμων. Με αυτόν τον τρόπο, οι πλατφόρμες μπορούν να αξιοποιούν τα οφέλη της εξατομίκευσης, περιορίζοντας παράλληλα τους κινδύνους που ενδέχεται να επηρεάσουν αρνητικά την εμπειρία και την εμπιστοσύνη των χρηστών.

7. ΚΕΦΑΛΑΙΟ 7: Μελέτη Περίπτωσης στην Ελληνική Αγορά

7.1.Skroutz: Συνδυασμός RS με Φίλτρα και Αγοραστική Συμπεριφορά

Η ελληνική αγορά ηλεκτρονικού εμπορίου παρουσιάζει τα τελευταία χρόνια αυξανόμενο ενδιαφέρον για την αξιοποίηση συστημάτων συστάσεων, με στόχο τη βελτίωση της εμπειρίας χρήστη και την ενίσχυση της αποδοτικότητας των ψηφιακών πλατφορμών (Stalidis et al., 2023). Η πλατφόρμα Skroutz αποτελεί χαρακτηριστικό παράδειγμα ενσωμάτωσης τέτοιων μηχανισμών στο ελληνικό επιχειρηματικό περιβάλλον, καθώς συνδυάζει τεχνικές προσωποποίησης, λειτουργίες φιλτραρίσματος και ανάλυση της αγοραστικής συμπεριφοράς των χρηστών.

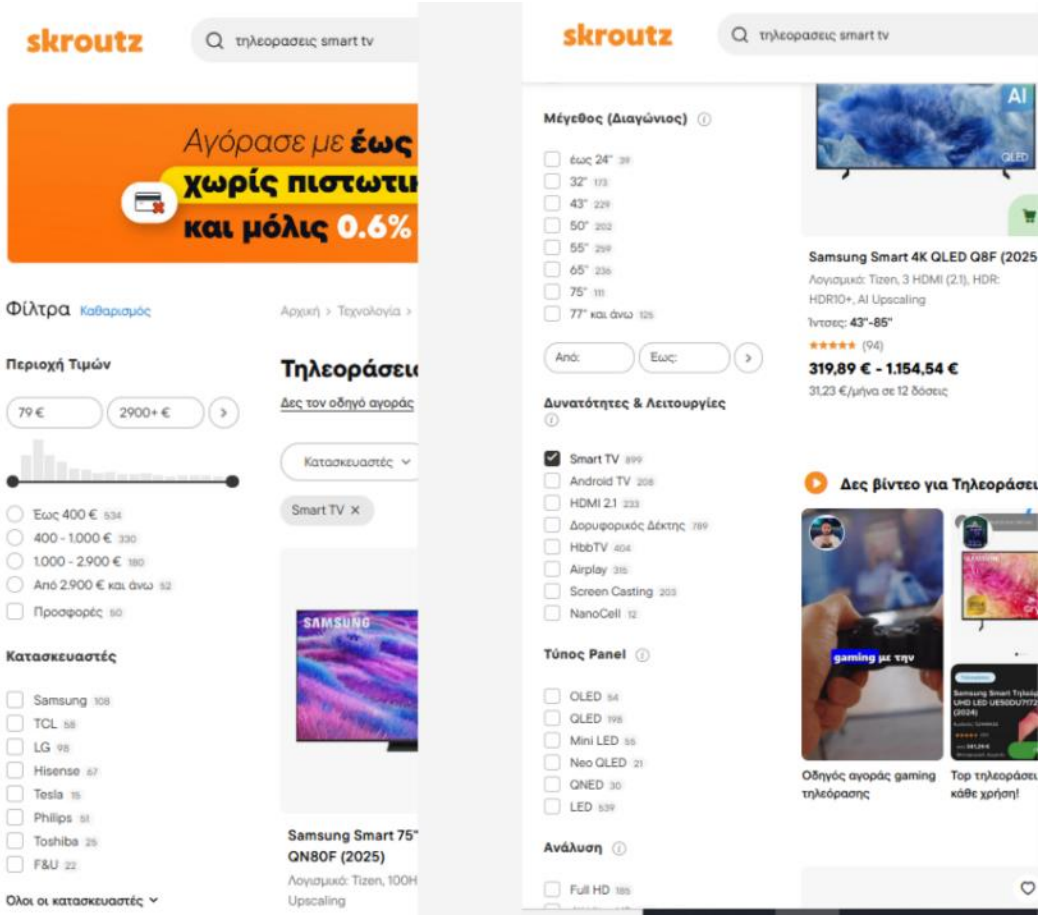
Όσον αφορά τη βασική του λειτουργία, το Skroutz συγκεντρώνει και οργανώνει μεγάλο όγκο προϊόντων από διαφορετικούς προμηθευτές, καλύπτοντας ένα ευρύ φάσμα καταναλωτικών αγαθών. Ο μεγάλος αριθμός διαθέσιμων επιλογών, φαινόμενο που συχνά αναφέρεται ως "υπερπληθώρα επιλογών" (Anderson, 2006), καθιστά αναγκαία τη χρήση μηχανισμών που διευκολύνουν την αναζήτηση, τη σύγκριση και την τελική επιλογή προϊόντων. Σε αυτό το πλαίσιο, τα recommender systems λειτουργούν συμπληρωματικά προς τα φίλτρα αναζήτησης, μια πρακτική που έχει αποδειχθεί ιδιαίτερα αποτελεσματική στο ηλεκτρονικό εμπόριο (Schafer, Konstan & Riedl, 2001). Ενώ τα φίλτρα επιτρέπουν στον χρήστη να περιορίσει τα αποτελέσματα με βάση συγκεκριμένα κριτήρια, όπως τιμή, μάρκα ή τεχνικά χαρακτηριστικά, τα συστήματα συστάσεων συμβάλλουν στη δυναμική προσαρμογή των αποτελεσμάτων με βάση τις προτιμήσεις, το ιστορικό αναζητήσεων και τη γενικότερη αγοραστική συμπεριφορά του χρήστη.

Η ιδιαιτερότητα της Skroutz έγκειται στον συνδυασμό δύο βασικών μηχανισμών όπως διαφαίνεται παρακάτω στον πίνακα 7.1.

Μηχανισμός	Λειτουργία	Παραδείγματα
Παραδοσιακά φίλτρα	Ο χρήστης περιορίζει ενεργά το σύνολο επιλογών	Τιμή, κατηγορία, μάρκα, χαρακτηριστικά, βαθμολογία
Recommender systems	Προτείνουν προϊόντα βάσει συμπεριφοράς	«Άλλοι χρήστες είδαν επίσης», «Βασισμένο στο ιστορικό σας»

Πίνακας 7 1 Συνδυασμός φίλτρων και RS στο Skroutz

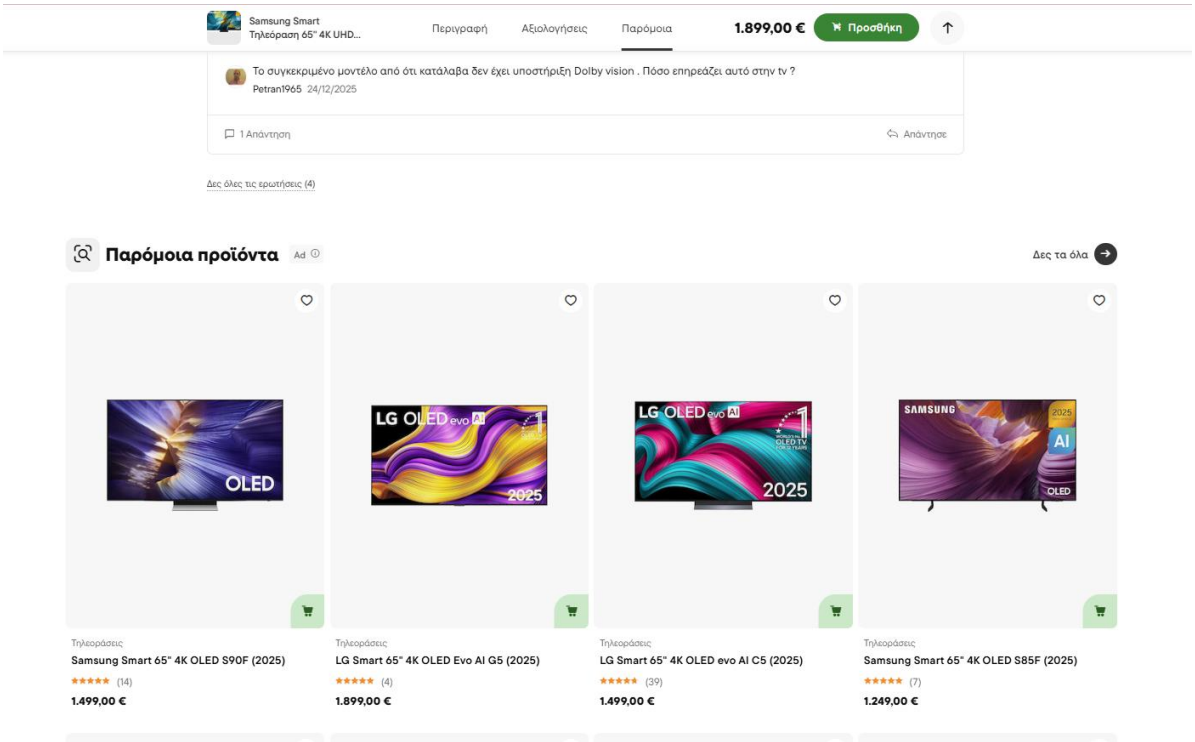
Όπως επισημαίνεται στη σχετική βιβλιογραφία (Jannach & Jugovac, 2019, Stalidis et al., 2023), ο συνδυασμός των φίλτρων αναζήτησης με τα συστήματα συστάσεων προσφέρει ένα σημαντικό πλεονέκτημα για τον χρήστη. Από τη μία πλευρά, ο χρήστης διατηρεί τον έλεγχο της αναζήτησης, επιλέγοντας ο ίδιος τα κριτήρια που θεωρεί σημαντικά. Από την άλλη πλευρά, επωφελείται από την εξατομίκευση που προσφέρουν τα RS, καθώς η πλατφόρμα μπορεί να του εμφανίζει προϊόντα που συνδέονται με τις προηγούμενες αναζητήσεις, τις προτιμήσεις ή τη γενικότερη αγοραστική του συμπεριφορά. Η Εικόνα 7.1 παρουσιάζει ενδεικτικά την περιοχή των φίλτρων της πλατφόρμας,



Εικόνα 7. 1

Χρήση φίλτρων αναζήτησης στο Skroutz. Ο χρήστης μπορεί να περιορίσει τα αποτελέσματα βάσει τιμής, κατηγορίας, μάρκας, χαρακτηριστικών και άλλων κριτηρίων, προτού λάβει εξατομικευμένες προτάσεις από το σύστημα συστάσεων. *Προσαρμογή από Jannach & Jugovac (2019) και Stalidis et al. (2023) Πηγή: Skroutz (screenshot από τον συγγραφέα, Μάιος 2026)*

ενώ η Εικόνα 7.2 απεικονίζει ένα παράδειγμα εξατομικευμένης πρότασης, όπως η ένδειξη «Παρόμοια Προϊόντα».

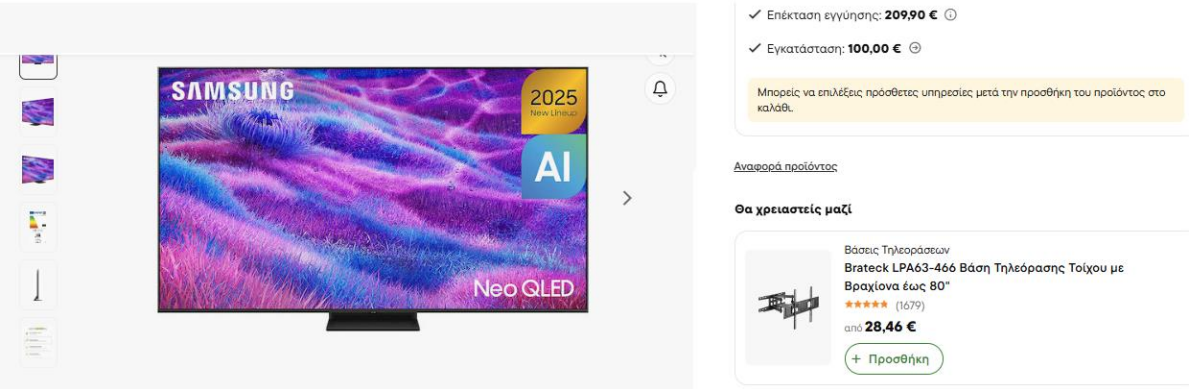


Εικόνα 7. 2

Παράδειγμα εξατομικευμένης πρότασης στο Skroutz με την ενότητα «Παρόμοια Προϊόντα». Το σύστημα συστάσεων προτείνει σχετικά προϊόντα βασισμένο στη συμπεριφορά άλλων χρηστών που ενδιαφέρθηκαν για το ίδιο προϊόν. *Προσαρμογή από Jannach & Jugovac (2019) και Stalidis et al. (2023). Πηγή: Skroutz (screenshot από τον συγγραφέα, Μάιος 2026)*

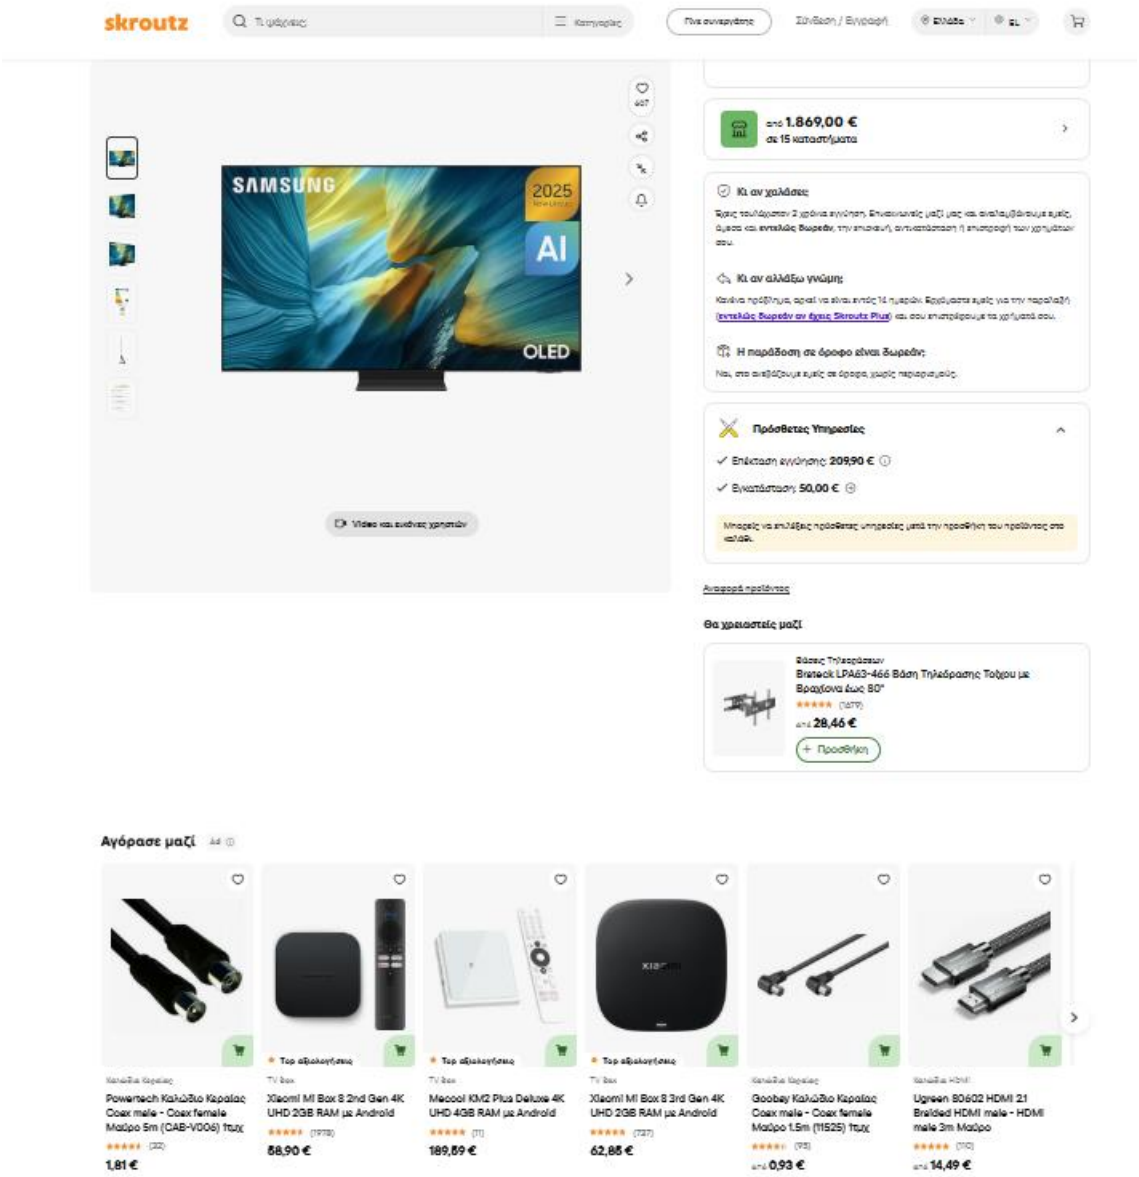
Σχετικά με την ανάλυση της αγοραστικής συμπεριφοράς, το Skroutz αξιοποιεί πολλαπλά δεδομένα, με στόχο τη διαμόρφωση προφίλ προτιμήσεων για κάθε χρήστη. Τα δεδομένα αυτά μπορεί να προέρχονται από το ιστορικό αναζητήσεων, τις προβολές προϊόντων, τις προσθήκες στο καλάθι, την εγκατάλειψη καλαθιού, τις αγορές, τις αξιολογήσεις χρηστών, καθώς και τον χρόνο παραμονής σε συγκεκριμένες σελίδες προϊόντων. Με βάση αυτές τις πληροφορίες, το σύστημα μπορεί να εντοπίζει πρότυπα αγοραστικής συμπεριφοράς και να προτείνει προϊόντα υψηλής συνάφειας. Έτσι, οι προτάσεις δεν βασίζονται μόνο στην άμεση αναζήτηση του χρήστη, αλλά και σε ευρύτερα μοτίβα συμπεριφοράς που προκύπτουν από τη χρήση της πλατφόρμας (Alamdari et al., 2020).

Παράλληλα, το Skroutz ενσωματώνει στοιχεία συλλογικής συμπεριφοράς, τα οποία παραπέμπουν στη λογική του collaborative filtering. Τέτοια στοιχεία είναι η ανάδειξη δημοφιλών προϊόντων, οι τάσεις της αγοράς και οι προτάσεις που βασίζονται στη συμπεριφορά άλλων χρηστών (Schafer, Konstan & Riedl, 2001). Η προσέγγιση αυτή συμβάλλει στην ανάδειξη προϊόντων που παρουσιάζουν αυξημένο ενδιαφέρον από την κοινότητα των χρηστών, ενώ παράλληλα ενισχύει την κοινωνική απόδειξη (social proof), καθώς ο χρήστης επηρεάζεται από τη συμπεριφορά και τις επιλογές άλλων καταναλωτών (Komiak & Benbasat, 2006). Στο πλαίσιο ενός ηλεκτρονικού καταστήματος όπως το Skroutz, η ψυχρή εκκίνηση αφορά κυρίως νέα προϊόντα που δεν έχουν ακόμα αξιολογηθεί ή αγοραστεί. Για την αντιμετώπισή της, το σύστημα μπορεί να βασιστεί σε χαρακτηριστικά περιεχομένου, όπως κατηγορία και τιμή, αντί για συμπεριφορικά δεδομένα (Gao et al., 2023). Το κλειδί βρίσκεται στον συνδυασμό φίλτρων και συστημάτων συστάσεων, ο οποίος προσφέρει σημαντικά οφέλη για την εμπειρία χρήστη. Μειώνει την πολυπλοκότητα της επιλογής, καθώς ο χρήστης δεν εκτίθεται σε χιλιάδες προϊόντα χωρίς κάποια μορφή οργάνωσης, και του επιτρέπει να περιορίσει τα αποτελέσματα με βάση συγκεκριμένα κριτήρια, λαμβάνοντας ταυτόχρονα προτάσεις που ανταποκρίνονται καλύτερα στις ανάγκες του. Για παράδειγμα, ένας χρήστης που αναζητά τηλεόραση μπορεί να χρησιμοποιήσει φίλτρα όπως εύρος τιμής, η Ανάλυση και το μέγεθος, ενώ το σύστημα μπορεί να του εμφανίσει προτάσεις τύπου «Άλλοι χρήστες που είδαν αυτήν την τηλεόραση, είδαν επίσης…», προτείνοντας σχετικά αξεσουάρ. Χαρακτηριστικό παράδειγμα εμφανίζεται στην Εικόνα 7.3 και 7.4, όπου στο αναζητούμενο είδος-τηλεόραση, εμφανίζεται λίστα προτεινόμενων προϊόντων «Αγόρασε μαζί» και «Θα χρειαστείς μαζί», όπου προτείνεται η αγορά βάσης στήριξης τοίχου για τηλεόραση ή διαφόρων καλωδίων εγκατάστασης.



Εικόνα 7. 3

Παράδειγμα εξατομικευμένων προτάσεων στο Skroutz με την ενότητα «Θα χρειαστείς μαζί». Το σύστημα συστάσεων προτείνει σχετικά προϊόντα βασισμένο στη συμπεριφορά άλλων χρηστών που ενδιαφέρθηκαν για το ίδιο προϊόν. *Πηγή: Skroutz (screenshot από τον συγγραφέα, Μάιος 2026)*



Εικόνα 7. 4

Παράδειγμα εξατομικευμένων προτάσεων στο Skroutz με την ενότητα «Αγόρασε μαζί». Το σύστημα συστάσεων προτείνει σχετικά προϊόντα βασισμένο στη συμπεριφορά άλλων χρηστών που ενδιαφέρθηκαν για το ίδιο προϊόν. *Πηγή: Skroutz (screenshot από τον συγγραφέα, Μάιος 2026)*

Με αυτόν τον τρόπο, ο χρήστης βρίσκει πιο γρήγορα το προϊόν που τον ενδιαφέρει, ενώ η πλατφόρμα ενισχύει και τη δυνατότητα cross selling (Jannach & Jugovac, 2019).

Ωστόσο, η εφαρμογή συστημάτων συστάσεων σε μια πλατφόρμα όπως το Skroutz συνοδεύεται και από ορισμένες προκλήσεις, οι οποίες συνδέονται με τα ιδιαίτερα χαρακτηριστικά της ελληνικής αγοράς. Σε σύγκριση με μεγάλες διεθνείς πλατφόρμες, η διαθεσιμότητα δεδομένων μπορεί να είναι πιο περιορισμένη, καθώς ο αριθμός των χρηστών και των συναλλαγών είναι μικρότερος, γεγονός που δυσκολεύει την εκπαίδευση και τη βελτιστοποίηση των αλγορίθμων (Stalidis et al., 2023). Επιπλέον, η ετερογένεια των χρηστών και η εποχικότητα της ζήτησης αποτελούν σημαντικούς παράγοντες που πρέπει να λαμβάνονται υπόψη. Οι καταναλωτές μπορεί να παρουσιάζουν διαφορετικά πρότυπα συμπεριφοράς ανάλογα με την περίοδο ή τις οικονομικές συνθήκες, και για τον λόγο αυτό, οι αλγόριθμοι χρειάζεται να προσαρμόζονται σε μικρότερα και συχνά πιο αραιά σύνολα δεδομένων, ώστε να παραμένουν αποτελεσματικοί (Alamdari et al., 2020).

Παρά τις προκλήσεις αυτές, η περίπτωση του Skroutz δείχνει ότι η αποτελεσματική ενσωμάτωση συστημάτων συστάσεων, σε συνδυασμό με παραδοσιακά φίλτρα αναζήτησης, μπορεί να προσφέρει σημαντική αξία ακόμη και σε αγορές μικρότερης κλίμακας (Stalidis et al., 2023).

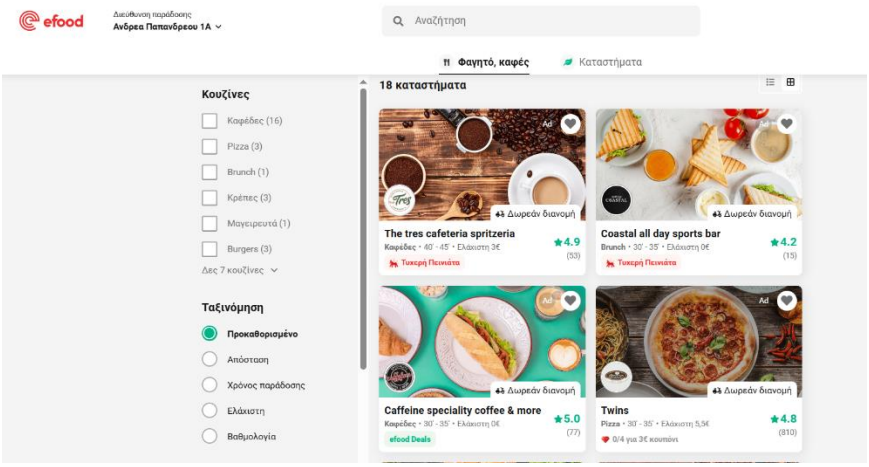
Εν κατακλείδι, η περίπτωση του Skroutz αναδεικνύει τη σημασία της προσαρμογής των recommender systems στα ιδιαίτερα χαρακτηριστικά της τοπικής αγοράς. Ο συνδυασμός φίλτρων, που διατηρούν τον έλεγχο στα χέρια του χρήστη, με μηχανισμούς εξατομίκευσης, που αξιοποιούν την αγοραστική συμπεριφορά και στοιχεία collaborative filtering, δημιουργεί ένα πιο λειτουργικό και αποτελεσματικό περιβάλλον αναζήτησης. Η προσέγγιση αυτή επιτρέπει την παροχή πιο σχετικών και χρήσιμων προτάσεων, ενισχύοντας τόσο την εμπειρία χρήστη όσο και την εμπορική απόδοση της πλατφόρμας.

7.2.E-food: Real-Time Συστάσεις με Βάση την Περιοχή

Η πλατφόρμα e-food αποτελεί ένα από τα πιο χαρακτηριστικά παραδείγματα εφαρμογής συστημάτων συστάσεων στην ελληνική αγορά (Stalidis et al., 2023). Η λειτουργία της βασίζεται σε μεγάλο βαθμό στην αξιοποίηση δεδομένων σε πραγματικό χρόνο (real-time), στην προσαρμογή των προτάσεων με βάση τη γεωγραφική τοποθεσία του χρήστη και στη χρήση συμφραζόμενων πληροφοριών (context). Σε αντίθεση με πιο παραδοσιακά recommender systems, τα οποία στηρίζονται κυρίως σε ιστορικά δεδομένα και προηγούμενες

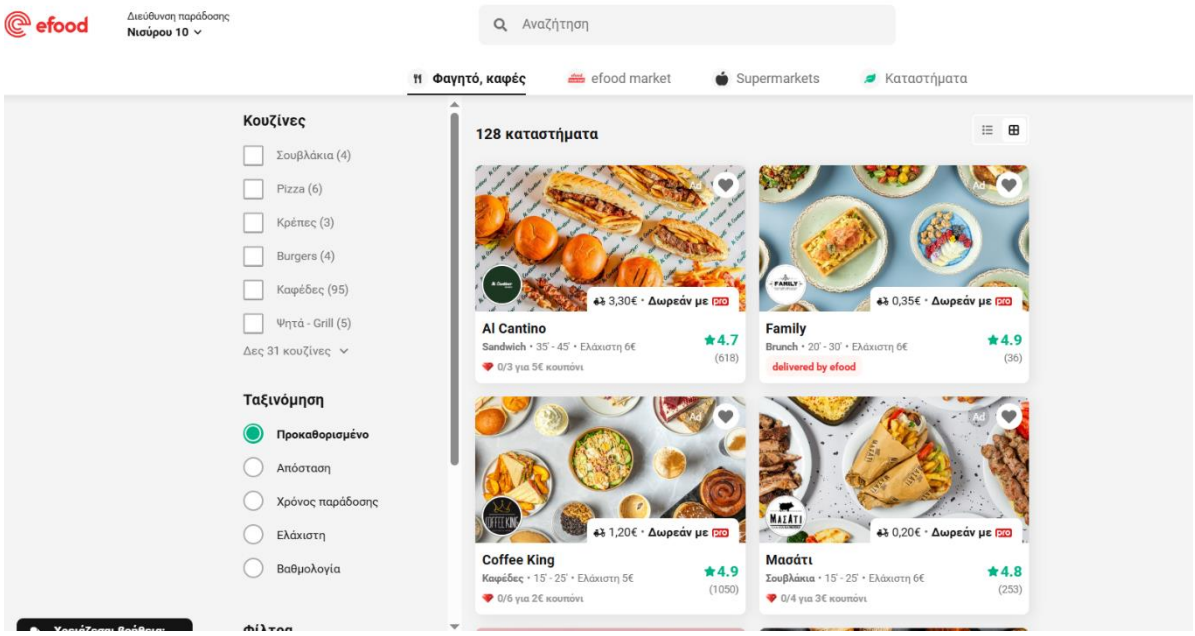
αλληλεπιδράσεις, το e-food δίνει ιδιαίτερη έμφαση στο άμεσο πλαίσιο χρήσης. Με άλλα λόγια, οι προτάσεις δεν βασίζονται μόνο στο τι έχει παραγγείλει ο χρήστης στο παρελθόν, αλλά και στο πού βρίσκεται, ποια καταστήματα είναι διαθέσιμα εκείνη τη στιγμή και ποιες επιλογές μπορούν πράγματι να εξυπηρετήσουν την τρέχουσα ανάγκη του.

Αρχικά, σημαντική παράμετρο αποτελεί η γεωγραφία. Η λειτουργία του συστήματος ξεκινά από τον εντοπισμό της τοποθεσίας του χρήστη, είτε μέσω GPS στην εφαρμογή κινητού είτε μέσω της διεύθυνσης που δηλώνεται στην ιστοσελίδα ή καταχωρείται χειροκίνητα. Με βάση αυτή την πληροφορία, το σύστημα περιορίζει δυναμικά το σύνολο των διαθέσιμων επιλογών, εμφανίζοντας μόνο τα καταστήματα που εξυπηρετούν τη συγκεκριμένη περιοχή. Η γεωγραφική διάσταση είναι ιδιαίτερα σημαντική, καθώς η δυνατότητα διανομής (delivery) επηρεάζει άμεσα το αν μια πρόταση είναι πρακτικά εφικτή. Σε αυτό το πλαίσιο, η συνάφεια δεν ορίζεται μόνο από τη γεωγραφική απόσταση, αλλά και από τον εκτιμώμενο χρόνο άφιξης στον πελάτη, μια παράμετρο που χρησιμοποιείται όλο και περισσότερο σε context-aware εφαρμογές για να διασφαλίσει ότι οι προτάσεις είναι πραγματικά προσβάσιμες (Mateos & Bellogín, 2025). Για παράδειγμα, ένας χρήστης που βρίσκεται στον Άγιο Νικόλαο θα δει διαφορετικές επιλογές εστιατορίων σε σχέση με έναν χρήστη που βρίσκεται στα βόρεια προάστια της Αθήνας ή σε μια άλλη πόλη. Επομένως, η τοποθεσία δεν λειτουργεί απλώς ως φίλτρο, αλλά ως βασική παράμετρος εξατομίκευσης και καταλληλότητας των προτάσεων. Οι Εικόνες 7.5 και 7.6 παρουσιάζουν ενδεικτικά ένα παράδειγμα λίστας προτάσεων εστιατορίων με βάση την τοποθεσία του χρήστη, όπου είναι διαφορετική για τον Άγιο Νικόλαο και άλλη για την περιοχή Βούλα της Αττικής.



Εικόνα 7.5:

Παράδειγμα προτάσεων εστιατορίων στο e-food με βάση την τοποθεσία του χρήστη, Άγιος Νικόλαος. *Πηγή: e-food (screenshot από τον συγγραφέα, Μάιος 2026)*



Εικόνα 7. 6

Παράδειγμα προτάσεων εστιατορίων στο e-food με βάση την τοποθεσία του χρήστη, Βούλα Αττικής. *Πηγή: e-food (screenshot από τον συγγραφέα, Μάιος 2026)*

Παράλληλα, το σύστημα συστάσεων του e-food αξιοποιεί δεδομένα που σχετίζονται με την αγοραστική συμπεριφορά του χρήστη. Τα δεδομένα αυτά περιλαμβάνουν προηγούμενες παραγγελίες όπως, τι έχει παραγγείλει ο χρήστης, από ποιο κατάστημα και σε ποια χρονική στιγμή, καθώς και προτιμήσεις ως προς το είδος της κουζίνας. Με βάση αυτά τα δεδομένα, διαμορφώνεται ένα προφίλ χρήστη, το οποίο επιτρέπει στο σύστημα να προσαρμόζει καλύτερα τις προτάσεις του (Alamdari et al., 2020). Έτσι, παρόμοιες επιλογές με προηγούμενες προτιμήσεις μπορούν να εμφανίζονται σε υψηλότερες θέσεις, ενώ καταστήματα που ο χρήστης φαίνεται να αποφεύγει μπορούν να προτείνονται λιγότερο συχνά. Με αυτόν τον τρόπο, οι προτάσεις γίνονται πιο σχετικές, πιο πρακτικές και περισσότερο προσαρμοσμένες στις πραγματικές ανάγκες του χρήστη. Παρακάτω στον Πίνακα 7.2 αποτυπώνονται real-time δεδομένα στο e-food και η επίδρασή τους στις προτάσεις.

Τύπος δεδομένων	Πώς επηρεάζει τις προτάσεις
Διαθεσιμότητα καταστημάτων	Αν ένα κατάστημα είναι κλειστό, δεν εμφανίζεται
Χρόνος παράδοσης	Συντομότεροι χρόνοι → υψηλότερη προτεραιότητα
Προσφορές & εκπτώσεις	Ενεργές προσφορές → ανάδειξη
Δημοτικότητα τη δεδομένη στιγμή	«Τι παραγγέλνουν τώρα άλλοι χρήστες στην περιοχή σας»

Πίνακας 7 2 Real-time δεδομένα στο e-food και επίδραση στις προτάσεις

Ωστόσο, θα αποτελούσε σοβαρή παράλειψη να μην αναφέρουμε πως το e-food αξιοποιεί στοιχεία συλλογικής συμπεριφοράς, τα οποία ενισχύουν τη λειτουργία των προτάσεων. Τέτοια στοιχεία μπορεί να είναι οι δημοφιλείς επιλογές σε μια συγκεκριμένη περιοχή, οι τάσεις κατανάλωσης ανά ώρα της ημέρας ή οι προτάσεις τύπου «Άλλοι χρήστες παρήγγειλαν επίσης» (Alamdari et al., 2020). Η αξιοποίηση αυτών των collaborative signals ενισχύει την εμπιστοσύνη του χρήστη, καθώς οι προτάσεις συνδέονται με τη συμπεριφορά άλλων καταναλωτών στην ίδια περιοχή ή σε παρόμοιο πλαίσιο. Παράλληλα, βοηθά στην ανακάλυψη νέων καταστημάτων, τα οποία ο χρήστης ενδεχομένως δεν θα αναζητούσε από μόνος του, αλλά εμφανίζονται ως δημοφιλείς ή σχετικές επιλογές.

Διαφοροποίηση από άλλους κλάδους

Η στρατηγική του e-food διαφοροποιείται σημαντικά από τις πλατφόρμες ηλεκτρονικού εμπορίου ή streaming. Όπως συνοψίζεται στον Πίνακα 7.3, στην περίπτωση του food delivery η σταθερότητα των προτιμήσεων είναι χαμηλότερη, καθώς οι ανάγκες του χρήστη μπορεί να αλλάζουν ανάλογα με την ώρα, την ημέρα, τη διάθεση ή την τοποθεσία του. Παράλληλα, η χρονική και η γεωγραφική διάσταση είναι ιδιαίτερα κρίσιμες. Σε αντίθεση με το ηλεκτρονικό εμπόριο ή το streaming, όπου ο χρήστης μπορεί συχνά να περιμένει ή να καταναλώσει το περιεχόμενο αργότερα, στο e-food η ανάγκη είναι άμεση. Για τον λόγο αυτό, οι real-time παράμετροι αποτελούν βασικό στοιχείο της λειτουργίας των συστημάτων συστάσεων στην πλατφόρμα (Du et al., 2022).

Χαρακτηριστικό	e-commerce (π.χ. Amazon)	Streaming (π.χ. Netflix)	e-food
Σταθερότητα προτιμήσεων	Υψηλή	Υψηλή	Χαμηλή (εξαρτάται από ώρα, διάθεση)
Χρονική διάσταση	Αμελητέα	Αμελητέα	Κρίσιμη (πρωί, μεσημέρι, βράδυ)
Γεωγραφική διάσταση	Χαμηλή (εξαίρεση: τοπικά προϊόντα)	Ανύπαρκτη	Κρίσιμη (περιοχή διανομής)
Real-time ανάγκη	Όχι (μπορεί να περιμένει)	Όχι (μπορεί να δει αργότερα)	Ναι (θέλει φαγητό τώρα)

Πίνακας 7 3: Διαφοροποίηση e-food από e-commerce και streaming

Προκλήσεις

Η εφαρμογή real-time recommender systems στο e-food συνοδεύεται από ορισμένες σημαντικές προκλήσεις, οι οποίες σχετίζονται κυρίως με τη δυναμική φύση της υπηρεσίας. Σε ένα περιβάλλον food delivery, οι συνθήκες μπορούν να μεταβάλλονται πολύ γρήγορα — η διαθεσιμότητα των καταστημάτων, οι χρόνοι παράδοσης, οι προσφορές και η ζήτηση ανά περιοχή αλλάζουν συνεχώς— γεγονός που απαιτεί ταχεία επεξεργασία και συνεχή ενημέρωση των δεδομένων. Μια ακόμη πρόκληση αφορά την ισορροπία ανάμεσα στην εξατομίκευση και την ποικιλία. Αν το σύστημα προτείνει συνεχώς τα ίδια καταστήματα, υπάρχει κίνδυνος να περιοριστεί η εμπειρία του χρήστη και να μειωθεί η δυνατότητα ανακάλυψης νέων επιλογών (Jannach & Jugovac, 2019).

Τέλος, στην περίπτωση του e-food, η ψυχρή εκκίνηση εμφανίζεται κυρίως με νέους χρήστες που δεν έχουν ακόμα ιστορικό παραγγελιών. Η λύση εστιάζει στην εκμετάλλευση γεωγραφικής τοποθεσίας και δημοφιλίας εστιατορίων ως εναλλακτικών σημάτων, μέχρι να συγκεντρωθούν αρκετά δεδομένα για πιο εξατομικευμένες συστάσεις (Gao et al., 2023). Γενικότερα, τα context-aware συστήματα συστάσεων αποδεικνύονται κρίσιμα σε υπηρεσίες

online παραγγελίας φαγητού, καθώς ενσωματώνουν δυναμικά τη χωροχρονική διάσταση για την παροχή άμεσων και σχετικών προτάσεων (Mateos & Bellogín, 2025· Du et al., 2022). Ανακεφαλαιώνοντας, η περίπτωση του e-food αναδεικνύει τη σημασία των context-aware και real-time recommender systems σε δυναμικά περιβάλλοντα υπηρεσιών. Η αξιοποίηση γεωγραφικών, χρονικών και real-time δεδομένων επιτρέπει την παραγωγή άμεσων, σχετικών και πρακτικά χρήσιμων προτάσεων. Σε συνδυασμό με την ανάλυση της συμπεριφοράς των χρηστών, τα δεδομένα αυτά ενισχύουν τόσο την εμπειρία χρήστη όσο και την επιχειρησιακή αποδοτικότητα της πλατφόρμας. Έτσι, το e-food αποτελεί χαρακτηριστικό παράδειγμα εφαρμογής συστημάτων συστάσεων που δεν βασίζονται μόνο στο ιστορικό προτιμήσεων, αλλά και στο άμεσο πλαίσιο μέσα στο οποίο πραγματοποιείται η επιλογή.

7.3.Public.gr: Απλές Μορφές Συστάσεων Βάσει Προφίλ

Η ελληνική πλατφόρμα ηλεκτρονικού εμπορίου Public.gr αποτελεί χαρακτηριστικό παράδειγμα εφαρμογής πιο απλών μορφών συστημάτων συστάσεων, οι οποίες βασίζονται κυρίως στο προφίλ και στη συμπεριφορά του χρήστη. Σε αντίθεση με πλατφόρμες μεγάλης κλίμακας, όπως η Amazon και το Netflix, όπου αξιοποιούνται σύνθετες τεχνικές, όπως βαθιά μάθηση και πολυεπίπεδα υβριδικά μοντέλα, το Public.gr υιοθετεί μια πιο πρακτική και οικονομικά αποδοτική προσέγγιση (Stalidis et al., 2023). Η επιλογή αυτή είναι περισσότερο προσαρμοσμένη στις ανάγκες και στους περιορισμούς της ελληνικής αγοράς, καθώς συνδέεται με το μικρότερο μέγεθος της αγοράς, τον περιορισμένο αριθμό χρηστών και συναλλαγών σε σχέση με διεθνείς πλατφόρμες, αλλά και με τη φύση της υπηρεσίας, η οποία αφορά το ηλεκτρονικό εμπόριο γενικών προϊόντων. Παράλληλα, λαμβάνονται υπόψη παράγοντες όπως οι διαθέσιμοι τεχνολογικοί και οικονομικοί πόροι, η υπολογιστική ισχύς, η τεχνογνωσία, καθώς και η ανάγκη για εύκολη συντήρηση και γρήγορη ενσωμάτωση των σχετικών λειτουργιών.

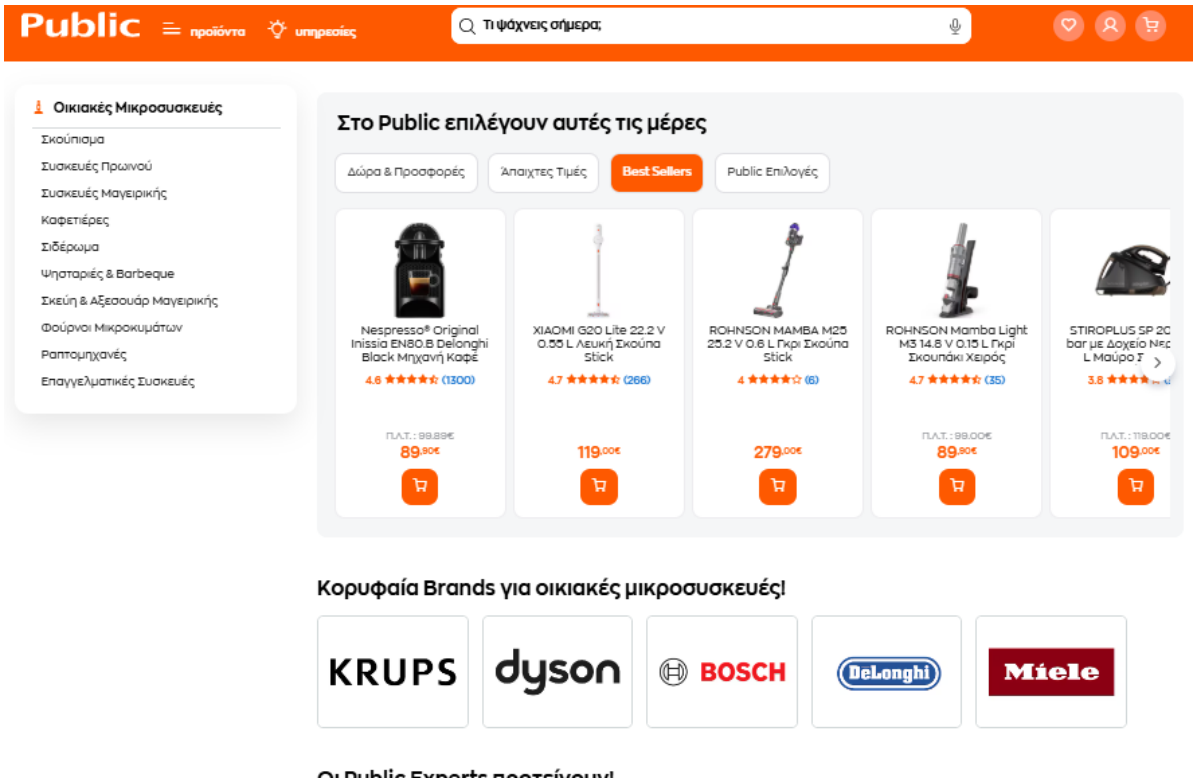
Το σύστημα συστάσεων του Public.gr βασίζεται κυρίως σε δεδομένα συμπεριφοράς και σε στοιχεία του προφίλ του χρήστη, χωρίς να απαιτεί ιδιαίτερα σύνθετες αλγοριθμικές υποδομές (Alamdari et al., 2020). Με αυτόν τον τρόπο, η πλατφόρμα μπορεί να παρέχει βασικές αλλά λειτουργικές προτάσεις προϊόντων, οι οποίες ενισχύουν την εμπειρία χρήστη και διευκολύνουν τη διαδικασία αναζήτησης και αγοράς (Schafer, Konstan & Riedl, 2001)

Στον παρακάτω πίνακα 7.4, βλέπουμε τι είδους δεδομένα αξιοποιούνται κυρίως:

Τύπος δεδομένων	Παραδείγματα
Ρητά δεδομένα	Αξιολογήσεις προϊόντων (βαθμολογίες, σχόλια)
Έμμεσα δεδομένα	Ιστορικό αγορών, αναζητήσεις, προβολές προϊόντων
Δημογραφικά	(περιορισμένα) – ηλικία, φύλο (προαιρετικά)
Δεδομένα περιεχομένου	Κατηγορία προϊόντος, μάρκα, τιμή

Πίνακας 7 4 Δεδομένα που αξιοποιούνται Public.gr

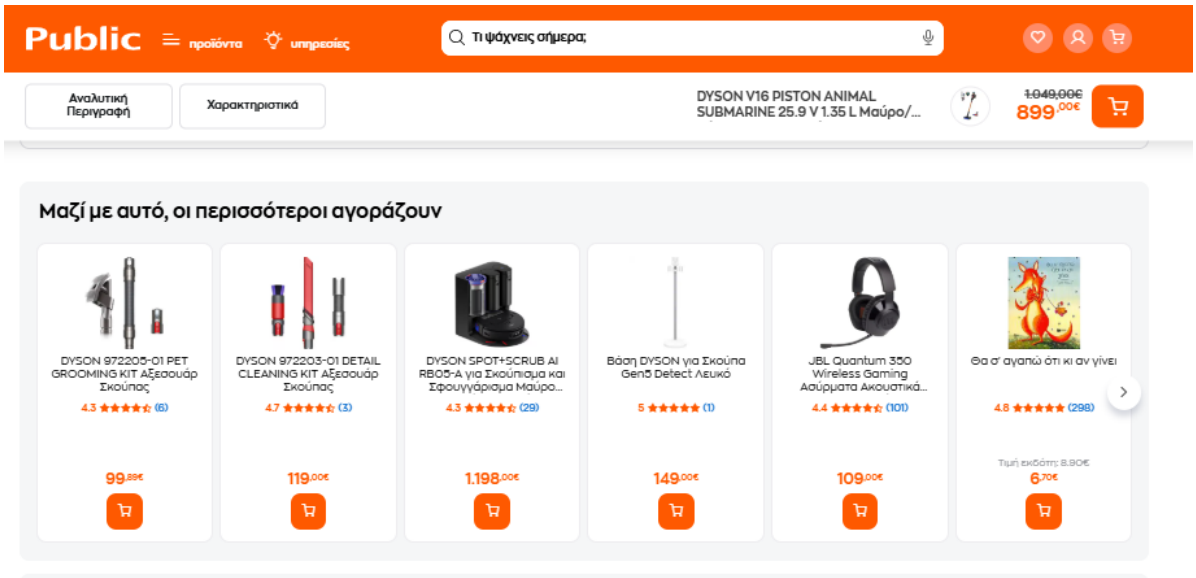
Οι προτάσεις που εμφανίζονται στο Public.gr μπορούν να διακριθούν σε τρεις βασικές μορφές, όπως συνοψίζονται παρακάτω στον Πίνακα 7.5. Η πρώτη μορφή αφορά προτάσεις βάσει δημοτικότητας, όπως «Τα πιο δημοφιλή τώρα» ή «Best sellers», οι οποίες στηρίζονται στη συνολική ζήτηση και στις προτιμήσεις του ευρύτερου αγοραστικού κοινού,βλ. Εικόνα 7.7.



Εικόνα 7. 7

Παράδειγμα προτεινόμενων προϊόντων στην πλατφόρμα Public.gr. Το σύστημα προτείνει προϊόντα βασισμένο σε δημοτικότητα. *Πηγή:* Public.gr *(screenshot από τον συγγραφέα, Μάιος 2026).*

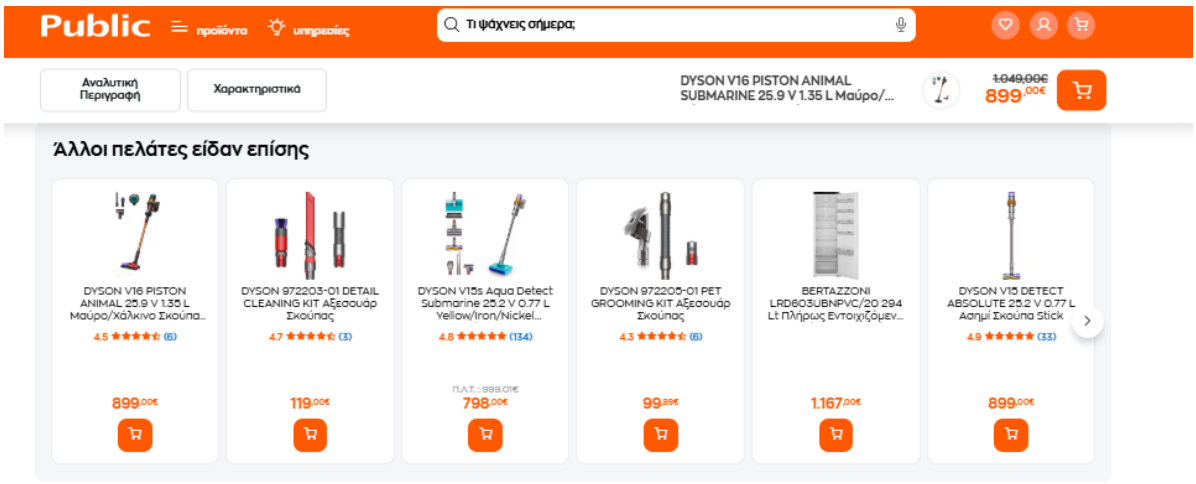
Η δεύτερη μορφή, απεικονίζεται παρακάτω στην εικόνα 7.8 και αφορά content-based προτάσεις, όπως «Παρόμοια προϊόντα» ή «Μαζί με αυτό οι περισσότεροι αγοράζουν», που βασίζονται στα χαρακτηριστικά του προϊόντος που εξετάζει ο χρήστης (Lops, Gemmis & Semeraro, 2011).



Εικόνα 7. 8

Παράδειγμα προτεινόμενων προϊόντων στην πλατφόρμα Public.gr. Το σύστημα προτείνει προϊόντα βασισμένο σε προηγούμενες αγορές του προϊόντος. *Πηγή:* Public.*gr (screenshot από τον συγγραφέα, Μάιος 2026).*

Η τρίτη μορφή σχετίζεται με απλές τεχνικές collaborative filtering, μέσα από ενδείξεις όπως «Όσοι είδαν αυτό, είδαν επίσης…», βλ. Εικόνα 7.9,οι οποίες αξιοποιούν στοιχεία συλλογικής συμπεριφοράς (Ricci, Rokach & Shapira, 2010)



Εικόνα 7. 9

Παράδειγμα προτεινόμενων προϊόντων στην πλατφόρμα Public.gr. Το σύστημα προτείνει προϊόντα βασισμένο σε προηγούμενες αγορές ή δημοτικότητα. *Πηγή:* Public.gr *(screenshot από τον συγγραφέα, Μάιος 2026).*

Μορφή	Περιγραφή	Παράδειγμα
Προτάσεις βάσει δημοτικότητας	Εμφάνιση δημοφιλών προϊόντων ή τάσεων στην κεντρική σελίδα	«Τα πιο δημοφιλή τώρα», «Best sellers»
Content-based προτάσεις	Προτάσεις προϊόντων με παρόμοια χαρακτηριστικά με αυτά που ο χρήστης έχει ήδη αγοράσει ή δει	«Παρόμοια προϊόντα», «Μαζί με αυτό οι περισσότεροι αγοράζουν»
Απλό collaborative filtering	«Όσοι είδαν αυτό, είδαν επίσης…»	Προτάσεις βασισμένες στη συμπεριφορά άλλων χρηστών

Πίνακας 7 5 Μορφές Προσωποποίησης κατηγοριών Public.gr

Content-Based vs Collaborative Filtering στο Public.gr

Η σύγκριση μεταξύ των δύο προσεγγίσεων αναδεικνύει διαφορετικά πλεονεκτήματα και περιορισμούς. Το content-based filtering βασίζεται κυρίως στα χαρακτηριστικά των προϊόντων, όπως η κατηγορία, η μάρκα, η τιμή ή άλλα τεχνικά γνωρίσματα. Δεν απαιτεί δεδομένα από άλλους χρήστες και συνήθως εμφανίζεται μέσα από προτάσεις τύπου «Παρόμοια προϊόντα». Βασικό του πλεονέκτημα είναι ότι μπορεί να λειτουργήσει ακόμη και όταν τα δεδομένα αλληλεπίδρασης είναι περιορισμένα, καθώς δεν επηρεάζεται στον ίδιο βαθμό από την αραιότητα των δεδομένων. Ωστόσο, βασικός περιορισμός του είναι η τάση προς υπερ-εξειδίκευση, καθώς συχνά προτείνει προϊόντα πολύ παρόμοια με εκείνα που έχει ήδη δει ο χρήστης. Αντίθετα, το collaborative filtering βασίζεται στο ιστορικό αγορών, στα clicks και στη συνολική συμπεριφορά άλλων χρηστών. Για να λειτουργήσει αποτελεσματικά, απαιτεί επαρκή δεδομένα αλληλεπίδρασης από πολλούς χρήστες και εμφανίζεται συνήθως μέσα από προτάσεις όπως «Όσοι είδαν αυτό, είδαν επίσης…». Το βασικό του πλεονέκτημα είναι ότι μπορεί να εντοπίσει μη προφανείς συσχετίσεις μεταξύ προϊόντων, βοηθώντας τον χρήστη να ανακαλύψει επιλογές που δεν θα προέκυπταν απαραίτητα μόνο από τα χαρακτηριστικά του προϊόντος. Ωστόσο, σε πλατφόρμες με σχετικά μικρή χρηστική βάση,

όπως το Public.gr, η ψυχρή εκκίνηση αποτελεί ιδιαίτερα έντονη πρόκληση λόγω της αραιότητας των δεδομένων. Σύμφωνα με τους Gao et al. (2023), η ενσωμάτωση υβριδικών μεθόδων που συνδυάζουν content-based και collaborative filtering μπορεί να μετριάσει αυτό το πρόβλημα ακόμα και σε συνθήκες περιορισμένης διαθεσιμότητας δεδομένων. Η σύγκριση που αποτυπώνεται στον πίνακα 7.6 παρακάτω, μεταξύ των δύο προσεγγίσεων αναδεικνύει διαφορετικά πλεονεκτήματα και περιορισμούς. Το content-based filtering βασίζεται κυρίως στα χαρακτηριστικά των προϊόντων και δεν απαιτεί δεδομένα από άλλους χρήστες, γεγονός που του επιτρέπει να λειτουργεί ακόμη και όταν τα δεδομένα αλληλεπίδρασης είναι περιορισμένα (Adomavicius & Tuzhilin, 2005). Ωστόσο, βασικός περιορισμός του είναι η τάση προς υπερ-εξειδίκευση (over-specialization), καθώς συχνά προτείνει προϊόντα πολύ παρόμοια με εκείνα που έχει ήδη δει ο χρήστης (Lops, Gemmis & Semeraro, 2011). Αντίθετα, το collaborative filtering μπορεί να εντοπίσει μη προφανείς συσχετίσεις μεταξύ προϊόντων, αλλά απαιτεί επαρκή δεδομένα αλληλεπίδρασης από πολλούς χρήστες (Ricci, Rokach & Shapira, 2010). Σε πλατφόρμες με σχετικά μικρή χρηστική βάση, όπως το Public.gr, η ψυχρή εκκίνηση αποτελεί ιδιαίτερα έντονη πρόκληση λόγω της αραιότητας των δεδομένων. Σύμφωνα με τους Gao et al. (2023), η ενσωμάτωση υβριδικών μεθόδων που συνδυάζουν content-based και collaborative filtering μπορεί να μετριάσει αυτό το πρόβλημα.

Κριτήριο	Content-based Filtering	Collaborative Filtering
Βασική αρχή	Ο χρήστης προτιμά προϊόντα παρόμοια με αυτά που ήδη του άρεσαν	Χρήστες με παρόμοια συμπεριφορά έχουν παρόμοιες προτιμήσεις
Τύπος δεδομένων	Χαρακτηριστικά προϊόντων (κατηγορία, μάρκα, τιμή)	Ιστορικό αγορών, προβολές, clicks
Ανάγκη για άλλους χρήστες	Όχι	Ναι
Παράδειγμα στο Public.gr	«Παρόμοια προϊόντα»	«Όσοι είδαν αυτό, είδαν επίσης…»
Πλεονέκτημα	Δεν επηρεάζεται από την αραιότητα δεδομένων	Ανακαλύπτει μη προφανείς συσχετίσεις
Μειονέκτημα	Υπερ-εξειδίκευση (over-specialization)	Cold start για νέα προϊόντα / χρήστες

Πίνακας 7 6 Content-based vs Collaborative Filtering στο Public.gr

Όπως συνοψίζεται στον Πίνακα 7.7, η απλούστερη προσέγγιση στα συστήματα συστάσεων παρουσιάζει ορισμένα σημαντικά πλεονεκτήματα, ιδιαίτερα για πλατφόρμες που λειτουργούν σε αγορές μικρότερης κλίμακας (Stalidis et al., 2023). Το κόστος ανάπτυξης είναι χαμηλότερο, η συντήρηση είναι ευκολότερη και η υλοποίηση μπορεί να γίνει σε μικρότερο χρονικό διάστημα. Ένα ακόμη πλεονέκτημα είναι η διαφάνεια, καθώς ο χρήστης μπορεί να κατανοήσει πιο εύκολα γιατί του προτάθηκε ένα συγκεκριμένο προϊόν (Jannach & Jugovac, 2019).

Ωστόσο, η απλούστερη αυτή προσέγγιση συνοδεύεται και από ορισμένους περιορισμούς. Η ακρίβεια των προτάσεων είναι συνήθως χαμηλότερη σε σχέση με πιο σύνθετα μοντέλα, και τα συστήματα αυτά προσαρμόζονται πιο δύσκολα σε γρήγορα μεταβαλλόμενες προτιμήσεις (Alamdari et al., 2020). Παράλληλα, υπάρχει κίνδυνος υπερ-εξειδίκευσης, καθώς οι προτάσεις μπορεί να περιορίζονται σε προϊόντα πολύ παρόμοια με όσα έχει ήδη δει ο χρήστης (Lops, Gemmis & Semeraro, 2011)

Πλεονέκτημα	Επεξήγηση
Χαμηλότερο κόστος ανάπτυξης	Δεν απαιτούνται εξειδικευμένες ομάδες data scientists, GPUs
Ευκολότερη συντήρηση	Απλούστεροι αλγόριθμοι, λιγότερα σημεία αποτυχίας
Ταχύτερη υλοποίηση	Μπορούν να τεθούν σε λειτουργία σε λίγες εβδομάδες
Μικρότερες απαιτήσεις δεδομένων	Δεν χρειάζονται τεράστια datasets για εκπαίδευση
Διαφάνεια	Ο χρήστης καταλαβαίνει εύκολα γιατί του προτάθηκε κάτι

Πίνακας 7 7 Τα οφέλη της απλούστερης προσέγγισης

Η σύγκριση του Public.gr με μεγάλες διεθνείς πλατφόρμες, όπως η Amazon και το Netflix, παρουσιάζεται στον Πίνακα 7.8. Το Public.gr χαρακτηρίζεται από χαμηλότερη πολυπλοκότητα, καθώς αξιοποιεί κυρίως content-based τεχνικές και απλές μορφές collaborative filtering. Η προσέγγιση αυτή έχει μικρότερες απαιτήσεις σε δεδομένα, χαμηλότερο κόστος υλοποίησης και μεγαλύτερη καταλληλότητα για τα δεδομένα της

ελληνικής αγοράς. Αντίθετα, οι μεγάλες διεθνείς πλατφόρμες εφαρμόζουν πιο σύνθετες προσεγγίσεις, οι οποίες απαιτούν τεράστιους όγκους δεδομένων και υψηλή υπολογιστική ισχύ. Παρότι προσφέρουν υψηλότερη ακρίβεια, η εφαρμογή τους σε μια μικρότερη αγορά μπορεί να είναι οικονομικά μη αποδοτική (Jannach & Jugovac, 2019).

Χαρακτηριστικό	Public.gr	Amazon / Netflix
Πολυπλοκότητα RS	Χαμηλή	Υψηλή
Τεχνικές	Content-based, απλό CF	Deep learning, matrix factorization, embeddings, online learning
Απαιτήσεις δεδομένων	Μικρές	Τεράστιες
Κόστος υλοποίησης	Χαμηλό	Πολύ υψηλό
Ακρίβεια προτάσεων	Μέτρια	Πολύ υψηλή
Καταλληλότητα για ελληνική αγορά	Υψηλή (ρεαλιστική)	Χαμηλή (απαγορευτική)

Πίνακας 7 8 Σύγκριση Public.gr με Amazon / Netflix

Καταλήγοντας, η περίπτωση το Public.gr αναδεικνύει ότι ακόμη και οι απλούστερες μορφές συστημάτων συστάσεων μπορούν να προσφέρουν ουσιαστική αξία στην ελληνική αγορά (Stalidis et al., 2023). Η αξιοποίηση μοντέλων βάσει προφίλ, content-based τεχνικών και απλών μορφών collaborative filtering μπορεί να αποτελέσει μια πρακτική και οικονομικά βιώσιμη λύση, ιδιαίτερα για επιχειρήσεις που δεν διαθέτουν τους πόρους ή τα δεδομένα μεγάλων διεθνών πλατφορμών. Η προσέγγιση αυτή επιτρέπει την ευρύτερη υιοθέτηση recommender systems από μικρομεσαίες επιχειρήσεις, τη βελτίωση της εμπειρίας χρήστη με σχετικά χαμηλό κόστος και τη σταδιακή αύξηση των πωλήσεων χωρίς την ανάγκη μεγάλων επενδύσεων σε σύνθετες τεχνολογικές υποδομές. Η περίπτωση αυτή δείχνει ότι η επιτυχής αξιοποίηση των RS δεν προϋποθέτει απαραίτητα ιδιαίτερα πολύπλοκες τεχνολογίες, αλλά κυρίως σωστή προσαρμογή στις ανάγκες, στις δυνατότητες και στα δεδομένα της εκάστοτε αγοράς.

7.4.Περιορισμοί Ελληνικής Αγοράς (Υποδομές, Προσωπικά Δεδομένα)

Η εφαρμογή συστημάτων συστάσεων στην ελληνική αγορά παρουσιάζει σημαντικές ιδιαιτερότητες και περιορισμούς σε σύγκριση με μεγαλύτερες διεθνείς αγορές, όπως οι ΗΠΑ και η Βόρεια Ευρώπη. Το ελληνικό ψηφιακό οικοσύστημα χαρακτηρίζεται από μικρότερη κλίμακα, περιορισμένη διαθεσιμότητα δεδομένων και διαφορετικές απαιτήσεις υλοποίησης (Stalidis et al., 2023). Οι κυριότεροι περιορισμοί παρουσιάζονται αναλυτικά παρακάτω και συνοψίζονται στον Πίνακα 7.9.

1. Τεχνολογικές υποδομές και πόροι

Πολλές ελληνικές επιχειρήσεις, ακόμη και στον τομέα του ηλεκτρονικού εμπορίου, δεν διαθέτουν πάντα την απαραίτητη υπολογιστική ισχύ, την εξειδικευμένη τεχνογνωσία και τα κεφάλαια που απαιτούνται για την ανάπτυξη σύνθετων συστημάτων συστάσεων. Η υλοποίηση προηγμένων αλγορίθμων, όπως deep learning ή real-time recommender systems, προϋποθέτει σημαντικές επενδύσεις σε υποδομές και εξειδικευμένο προσωπικό (Jannach & Jugovac, 2019).

Το γεγονός αυτό λειτουργεί συχνά αποτρεπτικά, ιδιαίτερα για μικρομεσαίες επιχειρήσεις. Ως αποτέλεσμα, πολλές ελληνικές επιχειρήσεις τείνουν να υιοθετούν απλούστερες λύσεις, αντίστοιχες με αυτές που παρατηρούνται σε πλατφόρμες όπως το Public.gr. Οι λύσεις αυτές ενδέχεται να προσφέρουν χαμηλότερη ακρίβεια σε σχέση με πιο σύνθετα μοντέλα, ωστόσο έχουν χαμηλότερο κόστος, είναι ευκολότερες στη συντήρηση και μπορούν να εφαρμοστούν πιο άμεσα.

2. Περιορισμένη κλίμακα και αραιότητα δεδομένων (data sparsity)

Τα συστήματα συστάσεων βασίζονται σε μεγάλο βαθμό σε δεδομένα αλληλεπίδρασης, ώστε να μπορούν να εντοπίζουν αξιόπιστα πρότυπα και συσχετίσεις. Στην ελληνική αγορά, ο μικρότερος αριθμός χρηστών, οι λιγότερες συναλλαγές ανά χρήστη και η χαμηλότερη συχνότητα αλληλεπιδράσεων οδηγούν σε εντονότερο πρόβλημα αραιότητας δεδομένων (data sparsity).

Όπως επισημαίνουν οι Alamdari et al. (2020), η αραιότητα των δεδομένων δυσχεραίνει τον εντοπισμό αξιόπιστων συσχετίσεων, μειώνει την ακρίβεια των προτάσεων και επηρεάζει ιδιαίτερα την αποτελεσματικότητα των αλγορίθμων collaborative filtering. Για παράδειγμα, σε μια μεγάλη διεθνή πλατφόρμα, όπως η Amazon, ένα προϊόν μπορεί να διαθέτει χιλιάδες

αξιολογήσεις και μεγάλο αριθμό αλληλεπιδράσεων. Αντίθετα, σε μια ελληνική πλατφόρμα, το ίδιο ή αντίστοιχο προϊόν μπορεί να έχει μόλις λίγες αξιολογήσεις, γεγονός που καθιστά δυσκολότερη την αξιόπιστη πρόβλεψη των προτιμήσεων των χρηστών.

3. GDPR και διαχείριση προσωπικών δεδομένων

Ένας ακόμη σημαντικός περιορισμός αφορά τη διαχείριση των προσωπικών δεδομένων. Η εφαρμογή του General Data Protection Regulation (GDPR) έχει θέσει αυστηρούς κανόνες σχετικά με τη συλλογή, την επεξεργασία και την αξιοποίηση δεδομένων χρηστών. Οι επιχειρήσεις οφείλουν να συλλέγουν δεδομένα μόνο με ρητή συγκατάθεση, να ενημερώνουν με διαφάνεια τους χρήστες για τον τρόπο χρήσης των δεδομένων τους και να διασφαλίζουν δικαιώματα όπως το δικαίωμα διαγραφής και το δικαίωμα φορητότητας.

Σύμφωνα με τους Tejeda-Lorente et al. (2018), η εφαρμογή του GDPR επιβάλλει σημαντικούς περιορισμούς στον τρόπο συλλογής και επεξεργασίας προσωπικών δεδομένων από τα RS, επηρεάζοντας άμεσα τη δυνατότητα εξατομίκευσης και τη διαχείριση προφίλ χρηστών. Παράλληλα, οι χρήστες στην ελληνική αγορά εμφανίζονται συχνά επιφυλακτικοί ως προς την παροχή προσωπικών πληροφοριών, γεγονός που μπορεί να οδηγήσει σε χαμηλότερα ποσοστά συγκατάθεσης, λιγότερα διαθέσιμα δεδομένα και μειωμένη εμπιστοσύνη απέναντι στις ψηφιακές υπηρεσίες.

4. Ετερογένεια και απομόνωση συστημάτων

Σε αντίθεση με μεγάλες διεθνείς εταιρείες, όπως η Amazon ή η Google, οι οποίες διαθέτουν ενιαία ψηφιακά οικοσυστήματα και μπορούν να αξιοποιούν δεδομένα από πολλαπλές υπηρεσίες, πολλές ελληνικές επιχειρήσεις λειτουργούν με πιο απομονωμένα συστήματα. Για παράδειγμα, το ηλεκτρονικό κατάστημα μπορεί να μην είναι πλήρως συνδεδεμένο με το CRM, τα δεδομένα της εφαρμογής κινητού να μην ενοποιούνται με τα δεδομένα του web, ή διαφορετικές πλατφόρμες να μη μοιράζονται μεταξύ τους πληροφορίες.

Η απομόνωση αυτή περιορίζει την ολοκληρωμένη αξιοποίηση των δεδομένων και δυσκολεύει τη δημιουργία πλήρων και αξιόπιστων προφίλ χρηστών (Alamdari et al., 2020). Ως αποτέλεσμα, οι προτάσεις που παράγονται μπορεί να βασίζονται σε αποσπασματικές πληροφορίες και να μην αποτυπώνουν με ακρίβεια τη συνολική συμπεριφορά και τις πραγματικές προτιμήσεις του χρήστη.

5. Έλλειψη εξειδικευμένου ανθρώπινου δυναμικού

Η ανάπτυξη και η διαχείριση αποδοτικών συστημάτων συστάσεων απαιτεί εξειδικευμένες γνώσεις σε τομείς όπως η μηχανική μάθηση, η στατιστική, η ανάλυση δεδομένων και η μηχανική λογισμικού. Στην ελληνική αγορά, η ζήτηση για τέτοιους ρόλους είναι συχνά μεγαλύτερη από τη διαθέσιμη προσφορά, γεγονός που οδηγεί σε αυξημένο κόστος πρόσληψης, δυσκολία εύρεσης κατάλληλων στελεχών και συχνή εξάρτηση από εξωτερικούς συνεργάτες (Stalidis et al., 2023). Για μικρότερες επιχειρήσεις, ο περιορισμός αυτός μπορεί να αποτελέσει σημαντικό εμπόδιο στην ανάπτυξη πιο σύνθετων και αποδοτικών recommender systems.

Περιορισμός	Επίδραση στα RS	Εκτιμώμενη Επίδραση
Τεχνολογικές υποδομές	Δυσκολία υλοποίησης σύνθετων μοντέλων	Υψηλή
Αραιότητα δεδομένων (sparsity)	Μειωμένη ακρίβεια προτάσεων	Πολύ υψηλή
GDPR & ιδιωτικότητα	Περιορισμός συλλογής δεδομένων, ανάγκη συμμόρφωσης	Υψηλή
Ετερογένεια / απομόνωση συστημάτων	Αδυναμία ολοκληρωμένου προφίλ χρήστη	Υψηλή
Έλλειψη εξειδικευμένου προσωπικού	Δυσκολία ανάπτυξης και συντήρησης	Πολύ υψηλή

Πίνακας 7 9 Συνοπτικός πίνακας περιορισμών ελληνικής αγοράς και μια συνολική εκτίμηση βάσει της βιβλιογραφίας

Προοπτικές και συστάσεις

Παρά τους περιορισμούς που χαρακτηρίζουν την ελληνική αγορά, υπάρχουν σημαντικές προοπτικές για τη σταδιακή ανάπτυξη και ευρύτερη αξιοποίηση των συστημάτων συστάσεων. Η αύξηση της ψηφιακής ωριμότητας των χρηστών και η μεγαλύτερη εξοικείωση με τις ηλεκτρονικές υπηρεσίες δημιουργούν ευνοϊκότερες συνθήκες για την αποδοχή πιο εξατομικευμένων υπηρεσιών (Stalidis et al., 2023).

Παράλληλα, η εξέλιξη των τεχνολογιών μειώνει σταδιακά τα εμπόδια υλοποίησης. Οι φθηνότερες υπολογιστικές υποδομές μέσω cloud και τα εργαλεία ανοικτού κώδικα, όπως το Apache Mahout, μπορούν να καταστήσουν την ανάπτυξη recommender systems πιο προσιτή ακόμη και για μικρομεσαίες επιχειρήσεις (Owen et al., 2011). Επιπλέον, η ενίσχυση της εκπαίδευσης σε τομείς όπως το data science και η τεχνητή νοημοσύνη μπορεί να συμβάλει στη δημιουργία περισσότερου εξειδικευμένου ανθρώπινου δυναμικού. Τέλος, οι συνεργασίες μεταξύ επιχειρήσεων, ερευνητικών φορέων και εκπαιδευτικών ιδρυμάτων μπορούν να υποστηρίξουν την ανταλλαγή τεχνογνωσίας και την ανάπτυξη κοινών υποδομών δεδομένων. Καταλήγοντας, οι περιορισμοί της ελληνικής αγοράς αναδεικνύουν την ανάγκη προσαρμογής των συστημάτων συστάσεων στις τοπικές συνθήκες. Η αποτελεσματική αξιοποίησή τους προϋποθέτει την ανάπτυξη ρεαλιστικών λύσεων, τη συμμόρφωση με το κανονιστικό πλαίσιο, τη διαφάνεια στη χρήση των δεδομένων και τη διατήρηση της εμπιστοσύνης των χρηστών. Παράλληλα, απαιτείται σταδιακή επένδυση σε τεχνολογικές υποδομές και ανθρώπινο δυναμικό. Παρά τις υφιστάμενες δυσκολίες, η εξέλιξη των τεχνολογιών και η αύξηση της ψηφιακής ωριμότητας δημιουργούν προοπτικές για την περαιτέρω ανάπτυξη των recommender systems στην ελληνική αγορά (Stalidis et al., 2023· Matta & Stalidis, 2024). Όπως κατέδειξε η ανάλυση των μελετών περίπτωσης, ακόμη και απλές στρατηγικές υιοθέτησης RS μπορούν να αποτελέσουν παράγοντα διαφοροποίησης για τις ελληνικές επιχειρήσεις, επιβεβαιώνοντας ότι η αξία των RS δεν είναι προνόμιο μόνο των μεγάλων διεθνών πλατφορμών.

Πριν περάσουμε στα συνολικά συμπεράσματα, ο Πίνακας 7.10 συνοψίζει τη συγκριτική επισκόπηση όλων των μελετών περίπτωσης που αναλύθηκαν στα Κεφάλαια 5, 6 και 7, αποτυπώνοντας τα βασικά χαρακτηριστικά κάθε πλατφόρμας με βάση κοινά κριτήρια αξιολόγησης.

Πλατφόρμα	Κλάδος	Κύρια Μορφή Προσω-ποποίησης	Τεχνική Πολυπλοκότητα	Κύρια Πηγή Δεδομένων	Κύριος Επιχειρησιακός Στόχος	Βασικό Πλεονέκτημα	Βασική Πρόκληση
Amazon	Ηλ. εμπόριο	Item-based CF	Υψηλή	Ιστορικό αγορών, αναζητήσεις	Αύξηση πωλήσεων & AOV	Άμεση σύνδεση με έσοδα	Τεράστιος κατάλογος (SKUs)
Netflix	Streaming	Υβριδικά + Thumbnails	Πολύ υψηλή	Ιστορικό προβολών, παύσεις	Engagement & μείωση churn	Δυναμική προσαρμογή σε πραγματικό χρόνο	Δυναμικές προτιμήσεις, όγκος δεδομένων
Spotify	Μουσική	Deep learning + Playlists	Πολύ υψηλή	Ακρόαση, skips, playlists	Αύξηση χρόνου ακρόασης	Ανακάλυψη νέου περιεχομένου	Υπερ-εξειδίκευση (filter bubble)
Tripadvisor	Τουρισμός	Context-aware + Social proof	Υψηλή	Αξιολογήσεις, κριτικές	Υποστήριξη απόφασης & εμπιστοσύνη	Φιλτράρισμα χιλιάδων επιλογών	Data sparsity, ψεύτικες κριτικές
Skroutz	Ηλ. εμπόριο	Φίλτρα + CF + Content-based	Μέτρια	Αναζητήσεις, προβολές, αγορές	Βελτίωση αναζήτησης & cross-selling	Συνδυασμός φίλτρων και RS	Περιορισμένα δεδομένα, εποχικότητα
e-food	Food delivery	Real-time + Γεωγραφική τοποθεσία	Μέτρια	Τοποθεσία, παραγγελίες, ώρα	Άμεση εξυπηρέτηση & σχετικές προτάσεις	Συνάφεια βάσει πλαισίου (context)	Δυναμική φύση υπηρεσίας, real-time απαιτήσεις
Public	Ηλ. εμπόριο	Content-based + Απλό CF	Χαμηλή	Προφίλ χρήστη, αγορές	Βασική εξατομίκευση & εμπειρία	Οικονομικά βιώσιμη λύση	Χαμηλότερη ακρίβεια, υπερ-εξειδίκευση

Πίνακας 7 10 Συγκριτική επισκόπηση μελετών περίπτωσης βάσει κοινών κριτηρίων

8. ΚΕΦΑΛΑΙΟ 8: Συμπεράσματα και Προτάσεις

8.1. Ανακεφαλαίωση Κύριων Σημείων

Η παρούσα εργασία εξέτασε τον ρόλο και τη σημασία των συστημάτων συστάσεων στο σύγχρονο ψηφιακό περιβάλλον, αναδεικνύοντας τη συμβολή τους τόσο στη βελτίωση της εμπειρίας χρήστη όσο και στην ενίσχυση της επιχειρησιακής απόδοσης. Η ανάλυση οργανώθηκε σε τρία βασικά επίπεδα: θεωρητικό, επιχειρησιακό και τεχνολογικό. Παράλληλα, συμπληρώθηκε με μελέτες περίπτωσης από διεθνείς και ελληνικές πλατφόρμες, ώστε να αποτυπωθεί τόσο η γενική λειτουργία των RS όσο και η πρακτική τους εφαρμογή σε διαφορετικά επιχειρηματικά περιβάλλοντα.

Θεωρητικό επίπεδο, Κεφάλαια 2 και 3

Η εργασία ανέδειξε ότι η υπερπληθώρα επιλογών καθιστά απαραίτητους μηχανισμούς εξατομίκευσης. Καλύφθηκε η διάκριση των βασικών κατηγοριών RS (collaborative, content-based, υβριδικά) και οι κρίσιμες προκλήσεις απόδοσης.

*Όπως αναλύθηκε στο Κεφάλαιο 2, οι βασικές τεχνικές προκλήσεις (cold start, data sparsity, bias) παραμένουν κομβικές για την απόδοση των RS, απαιτώντας εξελιγμένες προσεγγίσεις και η ενσωμάτωση εννοιολογικών δεδομένων (context-awareness).

Σε επιχειρησιακό επίπεδο, διαπιστώθηκε ότι η εξατομίκευση συμβάλλει ουσιαστικά στη δημιουργία αξίας μέσω της αύξησης της δέσμευσης, των πωλήσεων και της διατήρησης πελατών, χωρίς ωστόσο να απουσιάζουν κίνδυνοι όπως η απώλεια εμπιστοσύνης, η υπερ-εξειδίκευση και τα ζητήματα ιδιωτικότητας

Τεχνολογικό επίπεδο, Κεφάλαιο 4

Σε τεχνολογικό επίπεδο, η εργασία ανέδειξε την τεχνητή νοημοσύνη ως βασικό μοχλό εξέλιξης των RS, με τεχνικές όπως η βαθιά μάθηση, τα Graph Neural Networks, τα embeddings και η παραγοντοποίηση μητρώων να επιτρέπουν την επεξεργασία μεγάλων όγκων δεδομένων και την εξαγωγή σύνθετων προτύπων συμπεριφοράς. Ιδιαίτερη έμφαση δόθηκε στις μελλοντικές εξελίξεις (LLMs, Conversational RS, Explainable RS), που μετατοπίζουν τα RS από απλά συστήματα πρόβλεψης προτιμήσεων σε διαδραστικά, ερμηνεύσιμα και προσαρμοστικά εργαλεία.

Μελέτες περίπτωσης, Κεφάλαια 5, 6 και 7

Από τις διεθνείς περιπτώσεις (Amazon, Netflix, Spotify, Tripadvisor) επιβεβαιώθηκε ότι οι μεγάλες πλατφόρμες επενδύουν σε υβριδικές αρχιτεκτονικές, real-time δεδομένα και context-aware μηχανισμούς, συνδέοντας άμεσα τα RS με μετρήσιμους επιχειρησιακούς δείκτες. Στην ελληνική αγορά, αντίθετα, οι εφαρμογές (Skroutz, e-food, Public.gr) είναι λιγότερο σύνθετες αλλά λειτουργικές, αποδεικνύοντας ότι ακόμη και απλούστερες προσεγγίσεις μπορούν να προσφέρουν αξία όταν προσαρμόζονται στην τοπική κλίμακα, στους πόρους και στο κανονιστικό πλαίσιο.

Οι απαντήσεις στα τέσσερα ερευνητικά ερωτήματα που τέθηκαν στην εισαγωγή παρουσιάζονται αναλυτικά στην επόμενη ενότητα.

Καταληκτικά, η αποτελεσματική αξιοποίηση των RS δεν εξαρτάται αποκλειστικά από την πολυπλοκότητα των αλγορίθμων, αλλά από την κατανόηση των αναγκών των χρηστών, τη διαθεσιμότητα/ποιότητα των δεδομένων και την προσαρμογή στα ιδιαίτερα χαρακτηριστικά κάθε αγοράς.

8.2. Απαντήσεις στα Ερευνητικά Ερωτήματα

Στη βάση της ανάλυσης που προηγήθηκε, τα τέσσερα ερευνητικά ερωτήματα της εργασίας μπορούν να απαντηθούν ως εξής:

1: Πώς ενσωματώνονται τα recommender systems στις επιχειρησιακές διαδικασίες και ποιες είναι οι επιπτώσεις τους στην απόδοση των επιχειρήσεων;

Τα RS παύουν να είναι απλά τεχνικά εργαλεία και ενσωματώνονται στον πυρήνα της επιχειρηματικής στρατηγικής. Επηρεάζουν κρίσιμες λειτουργίες, όπως οι πωλήσεις (upselling, cross-selling), το marketing (προσωποποιημένες καμπάνιες) και η διαχείριση πελατειακών σχέσεων (βλ. Κεφ. 3 και 5). Οι μελέτες περίπτωσης (Amazon, Netflix) επιβεβαιώνουν άμεσες θετικές επιπτώσεις σε KPIs όπως τα conversion rates, ο μέσος όρος εσόδων και η διατήρηση συνδρομητών, γεγονός που σταδιακά παρατηρείται και σε πιο περιορισμένη κλίμακα στην ελληνική αγορά (βλ. Κεφ. 7).

2: Ποια είναι τα βασικά πλεονεκτήματα και μειονεκτήματα των διαφορετικών κατηγοριών συστημάτων συστάσεων;

Όπως αναλύθηκε στο Κεφάλαιο 2, το συνεργατικό φιλτράρισμα υπερέχει στην ανακάλυψη μη προφανών συσχετίσεων αλλά υποφέρει από cold start και αραιότητα. Το φιλτράρισμα βάσει περιεχομένου είναι ανθεκτικό στην αραιότητα και ερμηνεύσιμο, αλλά τείνει στην

υπερ-εξειδίκευση. Τα υβριδικά μοντέλα επιτυγχάνουν καλύτερη ισορροπία, γι' αυτό και προτιμώνται από τις μεγάλες πλατφόρμες, συνδυάζοντας την ακρίβεια με την ποικιλία.

3: Ποιες τεχνολογικές τάσεις διαμορφώνουν το μέλλον των recommender systems και πώς επηρεάζουν τη χρήση τους στο ηλεκτρονικό εμπόριο;

Η ενσωμάτωση Μεγάλων Γλωσσικών Μοντέλων (LLMs) και Graph Neural Networks (GNNs) επιτρέπει πιο πλούσιες και διαδραστικές συστάσεις, ενώ τα Conversational RS αλλάζουν ριζικά την αλληλεπίδραση χρήστη-συστήματος (βλ. Κεφ. 4). Στο ηλεκτρονικό εμπόριο, οι τάσεις αυτές οδηγούν σε συστήματα που κατανοούν τη φυσική γλώσσα, προτείνουν βάσει πλαισίου σε πραγματικό χρόνο και εξηγούν τις προτάσεις τους, αυξάνοντας την εμπιστοσύνη.

4: Ποιες πρακτικές εφαρμογές των συστημάτων συστάσεων εντοπίζονται σε διεθνές και ελληνικό επίπεδο και ποια συμπεράσματα μπορούν να εξαχθούν σχετικά με την αποτελεσματικότητά τους;

Διεθνώς, πλατφόρμες όπως το Netflix και η Amazon αποτελούν πρότυπα αποτελεσματικότητας, συνδέοντας άμεσα τα RS με τα έσοδά τους. Στην Ελλάδα, εφαρμογές όπως το Skroutz και το e-food αποδεικνύουν ότι ακόμη και απλούστερες, οικονομικά βιώσιμες λύσεις (π.χ. content-based, φίλτρα και δημοφιλείς επιλογές) μπορούν να βελτιώσουν σημαντικά την εμπειρία χρήστη και την απόδοση, αρκεί να προσαρμόζονται στο τοπικό πλαίσιο (βλ. Κεφ. 7).

8.3.Επιπτώσεις για τις Επιχειρήσεις

Η υιοθέτηση συστημάτων συστάσεων έχει επιφέρει ουσιαστικές αλλαγές στον τρόπο λειτουργίας, ανάπτυξης και ανταγωνισμού των σύγχρονων επιχειρήσεων. Όπως επισημαίνουν οι Jannach και Jugovac (2019), τα recommender systems δεν αποτελούν πλέον απλώς τεχνολογικά εργαλεία υποστήριξης, αλλά κρίσιμους παράγοντες δημιουργίας αξίας και διαμόρφωσης ανταγωνιστικού πλεονεκτήματος. Η ανάλυση στις μελέτες περίπτωσης επιβεβαίωσε ότι η στρατηγική υιοθέτηση των RS δεν βελτιώνει μόνο άμεσα KPIs όπως το conversion rate και το engagement, αλλά αποτελεί πλέον κρίσιμο παράγοντα διαφοροποίησης και στην ελληνική αγορά (Stalidis et al., 2023). Οι επιπτώσεις τους μπορούν να ομαδοποιηθούν στις κατηγορίες που παρουσιάζονται στον Πίνακα 8.1.

Κατηγορία	Θετικές επιπτώσεις	Προκλήσεις / Κίνδυνοι
Στρατηγικές	Εξατομίκευση, υψηλότερα conversion rates	Κίνδυνος filter bubble
Λειτουργικές	Upselling, cross-selling, retention	Ανάγκη για συνεχή βελτιστοποίηση
Πληροφοριακές	Αξιοποίηση δεδομένων για στρατηγικές αποφάσεις	Εξάρτηση από ιστορικά δεδομένα (αντί για καινοτομία)
Οικονομικές	Αύξηση εσόδων, μείωση κόστους	Υψηλές επενδύσεις, GDPR compliance

Πίνακας 8 1 Συνοπτικός πίνακας επιπτώσεων RS για επιχειρήσεις

Στρατηγικά, τα RS επιτρέπουν τη μετάβαση από μαζικές στρατηγικές marketing σε εξατομικευμένες προσεγγίσεις, αυξάνοντας την αποτελεσματικότητα των εμπορικών ενεργειών (Jannach & Jugovac, 2019). Λειτουργικά, υποστηρίζουν πρακτικές upselling και cross-selling, συμβάλλοντας στην αύξηση του μέσου καλαθιού αγορών και στη διατήρηση πελατών (Alamdari et al., 2020· Schafer, Konstan & Riedl, 2001). Σε πληροφοριακό επίπεδο, τα δεδομένα που συλλέγονται παρέχουν πολύτιμες πληροφορίες για τη λήψη τεκμηριωμένων αποφάσεων. Οι οικονομικές επιπτώσεις είναι σημαντικές, αν και συνοδεύονται από υψηλές απαιτήσεις σε επενδύσεις και συμμόρφωση με το κανονιστικό πλαίσιο (GDPR).

Παρά τα οφέλη, η ενσωμάτωση των RS ενέχει κινδύνους. Φαινόμενα όπως η υπερ-εξειδίκευση, το filter bubble και η αλγοριθμική μεροληψία μπορούν να υπονομεύσουν την εμπιστοσύνη των χρηστών (Nguyen et al., 2014· Gao et al., 2023). Η διαφάνεια, η ερμηνευσιμότητα και η προστασία της ιδιωτικότητας αναδεικνύονται επομένως σε αναγκαίες προϋποθέσεις για τη βιώσιμη αξιοποίησή τους.

Συμπερασματικά, οι επιπτώσεις των recommender systems για τις επιχειρήσεις είναι πολυδιάστατες και ιδιαίτερα σημαντικές. Η αποτελεσματική αξιοποίησή τους μπορεί να οδηγήσει σε βελτίωση της εμπειρίας πελάτη, αύξηση των εσόδων και ενίσχυση της ανταγωνιστικότητας. Ωστόσο, για να επιτευχθούν τα παραπάνω οφέλη, απαιτείται προσεκτικός σχεδιασμός και στρατηγική προσέγγιση. Οι επιχειρήσεις χρειάζεται να λάβουν υπόψη ζητήματα όπως το κόστος επενδύσεων, η συμμόρφωση με το GDPR και ο κίνδυνος

δημιουργίας filter bubbles, ώστε να περιορίσουν τις αρνητικές συνέπειες και να μεγιστοποιήσουν την αξία των συστημάτων συστάσεων.

8.4.Περιορισμοί της Παρούσας Μελέτης

Η παρούσα εργασία, όπως κάθε ερευνητική προσπάθεια, υπόκειται σε συγκεκριμένους περιορισμούς, οι οποίοι συνοψίζονται στον Πίνακα 8.2. Συνοπτικά, η ανάλυση στηρίχθηκε αποκλειστικά σε δευτερογενείς πηγές χωρίς πρωτογενή εμπειρικά δεδομένα, ενώ οι ακριβείς αλγοριθμικές λεπτομέρειες των διεθνών πλατφορμών παραμένουν εν μέρει απρόσιτες λόγω εμπορικού απορρήτου (Jannach & Jugovac, 2019). Η εστίαση σε συγκεκριμένους κλάδους και η ταχύτατη τεχνολογική εξέλιξη περιορίζουν τη γενικευσιμότητα και τη διαχρονικότητα των συμπερασμάτων (Gao et al., 2023). Ειδικότερα για την ελληνική αγορά, σε αντίθεση με διεθνείς πλατφόρμες όπως η Amazon και το Netflix, οι ελληνικές επιχειρήσεις δεν δημοσιοποιούν μετρήσιμα αποτελέσματα από τη χρήση RS, γεγονός που αποτελεί περιορισμό της παρούσας ανάλυσης (Stalidis et al., 2023). Η αξιολόγηση βασίζεται σε ποιοτικά στοιχεία και στη γενικότερη βιβλιογραφία του κλάδου. Η περιορισμένη διαθεσιμότητα βιβλιογραφίας και δεδομένων επηρέασε το βάθος της ανάλυσης, ενώ εκτενέστερες κοινωνικές και ηθικές προεκτάσεις δεν εξετάστηκαν (Adomavicius & Tuzhilin, 2005). Οι περιορισμοί αυτοί δεν αναιρούν τη συμβολή της μελέτης, αλλά αναδεικνύουν την ανάγκη για περαιτέρω εμπειρική διερεύνηση, ιδιαίτερα στην ελληνική πραγματικότητα.

Συνοπτικός πίνακας περιορισμών

Περιορισμός	Περιγραφή	Επίδραση στα συμπεράσματα
Μεθοδολογικός	Μόνο βιβλιογραφική ανασκόπηση, όχι πρωτογενή δεδομένα	Τα ευρήματα είναι θεωρητικά / ενδεικτικά
Μελετών περίπτωσης	Εξάρτηση από δημόσιες πηγές, εμπορικά απόρρητα	Αδυναμία πλήρους τεχνικής επαλήθευσης
Επιλογής περιπτώσεων	Εστίαση σε συγκεκριμένους κλάδους	Μη πλήρης γενίκευση
Τεχνολογικής εξέλιξης	Ταχύτατες αλλαγές (LLMs, generative AI)	Η εργασία αποτελεί «στιγμιότυπο»

Ελληνικής αγοράς	Έλλειψη βιβλιογραφίας και δεδομένων	Περιορισμένη πληρότητα ανάλυσης
Κοινωνικού/ηθικού εύρους	Χωρίς εκτενή ανάλυση bias, δικαιοσύνης, κοινωνικών επιπτώσεων	Μη πλήρης κάλυψη των διαστάσεων των RS

Πίνακας 8 2 Συνοπτικός πίνακας περιορισμών μελέτης

Οι παραπάνω περιορισμοί δεν αναιρούν τη συμβολή της παρούσας μελέτης. Αντίθετα, αναδεικνύουν την ανάγκη για περαιτέρω έρευνα, καθώς και τη σημασία εμπλουτισμού του πεδίου με εμπειρικά δεδομένα. Παράλληλα, καταδεικνύουν την ανάγκη για πιο εξειδικευμένες αναλύσεις, όπως συγκριτικές μελέτες αλγορίθμων, διερεύνηση των επιπτώσεων του filter bubble και ανίχνευση της αλγοριθμικής μεροληψίας (Gao et al., 2023· Nguyen et al., 2014).

Συνεπώς, η εργασία μπορεί να λειτουργήσει ως ένα στέρεο θεωρητικό υπόβαθρο για περαιτέρω διερεύνηση του ρόλου των recommender systems στο ψηφιακό περιβάλλον, με ιδιαίτερη έμφαση στην ελληνική αγορά.

8.5.Προτάσεις για Μελλοντική Έρευνα και Βελτίωση

Τα ευρήματα της παρούσας εργασίας, σε συνδυασμό με την ταχύτητα των τεχνολογικών εξελίξεων, αναδεικνύουν συγκεκριμένες προτεραιότητες για τη μελλοντική έρευνα. Οι προτάσεις που ακολουθούν οργανώνονται σε τέσσερις άξονες και αποτυπώνονται συνοπτικά, μαζί με την εκτίμηση της σημαντικότητάς τους, στον Πίνακα 8.3.

a. Τεχνολογική ενσωμάτωση και προσαρμογή

Η ενσωμάτωση σύγχρονων τεχνικών τεχνητής νοημοσύνης αποτελεί σαφή ερευνητική προτεραιότητα. Η διερεύνηση της αξιοποίησης Μεγάλων Γλωσσικών Μοντέλων (LLMs) και Graph Neural Networks (GNNs) μπορεί να προσφέρει πιο διαδραστικές, κατανοητές και βαθύτερα προσωποποιημένες συστάσεις (Gao et al., 2023· Fan et al., 2023). Παράλληλα, η εστίαση σε context-aware και, κυρίως, real-time προσεγγίσεις κρίνεται απαραίτητη, ιδιαίτερα για δυναμικά πεδία όπως το food delivery ή ο τουρισμός (Mateos & Bellogín, 2025· Du et al., 2022). Σε ένα δεύτερο επίπεδο, η ανάπτυξη Συνομιλιακών Συστημάτων Συστάσεων

(CRS) αναμένεται να μετασχηματίσει την αλληλεπίδραση χρήστη-συστήματος (Jannach & Jugovac, 2019).

b. Διαφάνεια, ηθική και ιδιωτικότητα

Η ανάγκη για αξιόπιστα και δίκαια συστήματα καθιστά επιτακτική την έρευνα σε Explainable RS (XRS), ώστε οι χρήστες να κατανοούν το σκεπτικό των προτάσεων (Adomavicius & Tuzhilin, 2005). Εξίσου σημαντική είναι η συστηματική μελέτη και αντιμετώπιση της αλγοριθμικής μεροληψίας (bias) και του φαινομένου του filter bubble, με στόχο τη διασφάλιση ποικιλίας και δικαιοσύνης στις προτεινόμενες επιλογές (Gao et al., 2023· Nguyen et al., 2014). Τέλος, η υιοθέτηση τεχνικών μηχανικής μάθησης που διατηρούν την ιδιωτικότητα (privacy-preserving) συνιστά κεντρικό ζητούμενο υπό το πρίσμα των σύγχρονων κανονιστικών πλαισίων (Tejeda-Lorente et al., 2018). Σε αυτό το πλαίσιο, υιοθετείται ολοένα και περισσότερο το μοντέλο «Human-in-the-loop», όπου η ανθρώπινη κρίση παραμένει ενεργή στη διαδικασία λήψης αποφάσεων, διασφαλίζοντας ότι οι αλγοριθμικές συστάσεις ευθυγραμμίζονται με ηθικές αρχές και εταιρικές αξίες (Adomavicius & Tuzhilin, 2005).

c. Εφαρμοσμένη έρευνα στην ελληνική αγορά

Για την τοπική αγορά, προτείνεται η ανάπτυξη ελαφριών, οικονομικά αποδοτικών μοντέλων RS, που μπορούν να υιοθετηθούν από μικρομεσαίες επιχειρήσεις (Stalidis et al., 2023). Η δημιουργία ανοικτών, ανωνυμοποιημένων ελληνικών datasets θα επιτρέψει την εξαγωγή ασφαλέστερων συμπερασμάτων και τη συγκριτική αξιολόγηση αλγορίθμων σε δεδομένα που αντανακλούν την τοπική πραγματικότητα. Η επίτευξη αυτών των στόχων προϋποθέτει στενότερη συνεργασία μεταξύ ακαδημαϊκών ιδρυμάτων και επιχειρήσεων.

d. Εμπειρική τεκμηρίωση και μακροχρόνια παρακολούθηση

Πέρα από τις βιβλιογραφικές προσεγγίσεις, το πεδίο χρειάζεται περισσότερες πρωτογενείς εμπειρικές μελέτες, όπως A/B testing και έρευνες χρηστών, που θα αξιολογούν την πραγματική αποτελεσματικότητα των αλγορίθμων (Jannach & Jugovac, 2019). Τέλος, η διεξαγωγή μακροχρόνιων διαχρονικών μελετών (longitudinal studies) κρίνεται απαραίτητη για την κατανόηση των μακροπρόθεσμων επιπτώσεων των RS στη συμπεριφορά, την ικανοποίηση και την εμπιστοσύνη των χρηστών.

Συνοπτικός πίνακας προτάσεων

Κατηγορία	Συγκεκριμένη πρόταση	Προτεραιότητα
Τεχνολογική	Ενσωμάτωση LLMs, GNNs, generative recommendation	Υψηλή
Τεχνολογική	Context-aware & real-time RS	Υψηλή
Τεχνολογική	Conversational RS (CRS)	Μεσαία
Διαφάνεια/Ηθική	Explainable RS (XRS)	Υψηλή
Διαφάνεια/Ηθική	Ανίχνευση & μείωση bias, fairness	Υψηλή
Διαφάνεια/Ηθική	Privacy-preserving techniques	Υψηλή
Ελληνική αγορά	Ελαφριά, οικονομικά RS	Πολύ υψηλή
Ελληνική αγορά	Δημιουργία ελληνικών datasets	Πολύ υψηλή
Ελληνική αγορά	Συνεργασία ακαδημίας-βιομηχανίας	Υψηλή
Εμπειρική έρευνα	Συλλογή πρωτογενών δεδομένων, A/B testing	Υψηλή
Εμπειρική έρευνα	Μακροχρόνιες διαχρονικές μελέτες	Μεσαία

Πίνακας 8 3 Συνοπτικός πίνακας προτάσεων για μελλοντική έρευνα (με προτεραιότητες)

ΒΙΒΛΙΟΓΡΑΦΙΑ

Α. ΞΕΝΟΓΛΩΣΣΗ

Adomavicius, G. & Tuzhilin, A. (2005) 'Toward the next generation of recommender systems: A survey of the state-of-the-art and possible extensions', *IEEE Transactions on Knowledge and Data Engineering*, 17(6), pp. 734–749.

Alamdari, P. M., Navimipour, N. J., Hosseinzadeh, M., Safaei, A. A. & Darwesh, A. (2020) 'A systematic study on the recommender systems in e-commerce', *IEEE Access*, 8, pp. 115694–115716.

Aldrich, S. E. (2011) 'Recommender systems in commercial use', *AI Magazine*, 32(3), pp. 28–34.

Amazon Web Services (2023) *Amazon Personalize: Developer guide*. Διαθέσιμο στο: https://docs.aws.amazon.com/personalize/latest/dg/what-is-personalize.html (Πρόσβαση: 6 Μαΐου 2026).

Anderson, C. (2006) *The long tail: Why the future of business is selling less of more*. Hyperion.

Bleier, A. & Eisenbeiss, M. (2015) 'Personalized online advertising effectiveness', *Journal of Marketing Research*, 52(3), pp. 390–409.

Bobadilla, J., Ortega, F., Hernando, A. & Gutiérrez, A. (2013) 'Recommender systems survey', *Knowledge-Based Systems*, 46, pp. 109–132.

Bollen, D., Knijnenburg, B. P., Willemsen, M. C. & Graus, M. (2010) 'Understanding choice overload in recommender systems', *Proceedings of the fourth ACM conference on Recommender systems*, pp. 63–70.

Brown, T., Mann, B., Ryder, N., Subbiah, M., Kaplan, J. D., Dhariwal, P., Neelakantan, A., Shyam, P., Sastry, G., Askell, A., Agarwal, S., Herbert-Voss, A., Krueger, G., Henighan, T., Child, R., Ramesh, A., Ziegler, D., Wu, J., Winter, C., Hesse, C., Chen, M., Sigler, E., Litwin, M., Gray, S., Chess, B., Clark, J., Berner, C., McCandlish, S., Radford, A., Sutskever, I. and Amodei, D. (2020) 'Language Models are Few-Shot Learners', *arXiv preprint arXiv:2005.14165.*

Burke, R. (2002) ‘Hybrid recommender systems: Survey and experiments’, *User Modeling and User-Adapted Interaction*, 12(4), pp. 331–370.

Burke, R., Mobasher, B., Bhaumik, R. & Williams, C. (2005) ‘Segment-based injection attacks against collaborative filtering recommender systems’, *Proceedings of the Fifth IEEE International Conference on Data Mining (ICDM'05)*, pp. 577–580. doi: 10.1109/ICDM.2005.126.

Cheng, M., Gao, Y., Liu, G., Jin, H. & Zhang, X. (2022) ‘EasyRec: An easy-to-use, extendable and efficient framework for building industrial recommendation systems’, *arXiv preprint*, arXiv:2209.12766. Διαθέσιμο στο: https://arxiv.org/abs/2209.12766 (Πρόσβαση: 6 Μαΐου 2026).

Claypool, M., Gokhale, A., Miranda, T., Murnikov, P., Netes, D. & Sartin, M. (1999) ‘Combining content-based and collaborative filters in an online newspaper’, *Proceedings of the ACM SIGIR Workshop on Recommender Systems*, pp. 40-48.

Deldjoo, Y., Schedl, M., Elahi, M. & Cremonesi, P. (2020) ‘Recommender systems leveraging multimedia content’, *ACM Computing Surveys*, 53(5), pp. 1–38.

Devlin, J., Chang, M. W., Lee, K. and Toutanova, K. (2018) 'BERT: Pre-training of Deep Bidirectional Transformers for Language Understanding', *arXiv preprint arXiv:1810.04805*.

Du, B., et al. (2022) ‘BASM: A Bottom-up Adaptive Spatiotemporal Model for Online Food Ordering Service’, *arXiv preprint*, arXiv:2211.12033v1.

Fan, W., Zhao, Z., Li, J., Liu, Y., Mei, X., Wang, Y., Tang, J. and Li, Q. (2023) 'Recommender Systems in the Era of Large Language Models (LLMs)', *IEEE Transactions on Knowledge and Data Engineering*, doi: 10.1109/TKDE.2023.3331006.

Field, A. (2013) *Discovering Statistics Using IBM SPSS Statistics*. 4th edn. London: Sage.

Fleder, D. & Hosanagar, K. (2009) ‘Blockbuster culture’s next rise or fall: The impact of recommender systems on sales diversity’, *Management Science*, 55(5), pp. 697–712.

European Commission (2021) *Proposal for a Regulation of the European Parliament and of the Council laying down harmonised rules on artificial intelligence (Artificial Intelligence Act)*. COM/2021/206 final. Διαθέσιμο στο: https://eur-lex.europa.eu/legal-content/EN/TXT/?uri=CELEX:52021PC0206 (Πρόσβαση: 12 Μαΐου 2026)

Gao, C., Zheng, Y., Li, N., Li, Y., Qin, Y., Piao, J. & Li, Y. (2023) ‘A survey of graph neural networks for recommender systems: Challenges, methods, and directions’, *ACM Transactions on Recommender Systems*, 1(1), pp. 1–51.

Gomez-Uribe, C. A. & Hunt, N. (2015) 'The Netflix recommender system: Algorithms, business value, and innovation', *ACM Transactions on Management Information Systems*, 6(4), pp. 1–19.

Herlocker, J. L., Konstan, J. A., Terveen, L. G. & Riedl, J. T. (2004) 'Evaluating collaborative filtering recommender systems', *ACM Transactions on Information Systems*, 22(1), pp. 5–53.

Hoff, K. A. & Bashir, M. (2015) 'Trust in automation: Integrating empirical evidence on factors that influence trust', *Human Factors*, 57(3), pp. 407–434.

Huang, M. H. & Rust, R. T. (2018) 'Artificial intelligence in service', *Journal of Service Research*, 21(2), pp. 155–172.

Huang, X., Liu, Y. & Zhang, Z. (2025) 'Revenue-based personalized product recommendation considering stochastic purchase probability', *European Journal of Operational Research*, 312(1), pp. 145–162.

Jain, A. K. (2010) 'Data clustering: 50 years beyond K-means', *Pattern Recognition Letters*, 31(8), pp. 651–666.

Jannach, D. & Jugovac, M. (2019) 'Measuring the business value of recommender systems', *ACM Transactions on Management Information Systems*, 10(4), pp. 1–23.

Karthik, R. V. & Ganapathy, S. (2021) 'A fuzzy recommendation system for predicting the customers' interests using sentiment analysis', *Applied Soft Computing*, 108, 107396.

Komiak, S. Y. X. & Benbasat, I. (2006) 'The effects of personalization and familiarity on trust and adoption of recommendation agents', *MIS Quarterly*, 30(4), pp. 941–960.

Koren, Y., Bell, R. & Volinsky, C. (2009) 'Matrix factorization techniques for recommender systems', *Computer*, 42(8), pp. 30–37.

Kwon, O. (2007) 'Recommender systems for commercial use', *Expert Systems with Applications*, 32(3), pp. 946–954.

Linden, G., Smith, B. & York, J. (2003) 'Amazon.com recommendations: Item-to-item collaborative filtering', *IEEE Internet Computing*, 7(1), pp. 76–80.

Liu, Y., Wang, X. & Chen, H. (2024) 'Social-aware Gaussian pre-trained model for cold-start recommendation', *Information Sciences*, 658, 120456.

Lops, P., Gemmis, M. D. & Semeraro, G. (2011) 'Content-based recommender systems: State of the art and trends', in Ricci, F., Rokach, L., Shapira, B. & Kantor, P. B. (eds.) *Recommender Systems Handbook*. Boston, MA: Springer, pp. 73–105.

Lu, J., Wu, D., Mao, M., Wang, W. & Zhang, G. (2015) 'Recommender system application developments: A survey', *Decision Support Systems*, 74, pp. 12–32.

Manning, C. D., Raghavan, P. & Schütze, H. (2008) *Introduction to Information Retrieval*. Cambridge: Cambridge University Press

MacKenzie, I., Meyer, C. & Noble, S. (2013) *How Retailers Can Keep Up With Consumers*. McKinsey & Company.

Mateos, P. & Bellogín, A. (2025) 'A systematic literature review of recent advances on context-aware recommender systems', *Artificial Intelligence Review*, 58(20). doi: 10.1007/s10462-024-10939-4.

Matta, E. & Stalidis, G. (2026) 'Data-Driven Exploration of Shopping Behaviour in e-Grocery: Comparing Online and Offline Customers', in *Advances in Advertising Research XV: Moving Forward, Looking Back: Advertising in the Advent of AI*. Wiesbaden: Springer Fachmedien Wiesbaden, pp. 155–174.

Mikolov, T., Sutskever, I., Chen, K., Corrado, G. S. & Dean, J. (2013) 'Distributed representations of words and phrases and their compositionality', *Advances in Neural Information Processing Systems*, 26, pp. 3111–3119

Monti, D., Rizzo, G. & Morisio, M. (2017) 'A systematic review of recommender systems software tools', *IEEE Access*, 5, pp. 16176–16191.

Nguyen, T. T., Hui, P., Harper, F. M., Terveen, L. & Konstan, J. A. (2014) 'Exploring the filter bubble', *Proceedings of the 23rd International Conference on World Wide Web*, pp. 677–686.

Owen, S., Anil, R., Dunning, T. & Friedman, E. (2011) *Mahout in Action*. Shelter Island, NY: Manning Publications.

Panagiotakis, C., Daskalaki, E., Papadakis, H. & Fragopoulou, P. (2022) 'The tourist trip design problem with POI categories via an expectation-maximization based method', *Workshop on Recommenders in Tourism*, pp. 1–8.

Panda, D. K. & Ray, P. (2022) 'Approaches and algorithms to mitigate cold start problems in recommender systems: a systematic literature review', *Information Retrieval Journal*, 25(3), pp. 295–344.

Papadakis, H., Papagrigoriou, A., Panagiotakis, C., Kosmas, E. & Fragopoulou, P. (2022) 'Collaborative filtering recommender systems taxonomy', *Knowledge and Information Systems*, 64(1), pp. 35–74.

Pappalardo, L., Ferretti, A., Sirbu, A. & Pedreschi, D. (2025) ‘A survey on the impacts of recommender systems on users, items, and human-AI ecosystems’, *ACM Computing Surveys*, 57(3), pp. 1–38.

Pazzani, M. J. & Billsus, D. (2007) ‘Content-based recommendation systems’, in Brusilovsky, P., Kobsa, A. & Nejdl, W. (eds.) *The Adaptive Web*. Berlin, Heidelberg: Springer, pp. 325–341.

Pu, P., Chen, L. & Hu, R. (2012) ‘Evaluating recommender systems from the user’s perspective’, *User Modeling and User-Adapted Interaction*, 22(4-5), pp. 317–355.

Resnick, P. & Varian, H. R. (1997) ‘Recommender systems’, *Communications of the ACM*, 40(3), pp. 56–58.

Ricci, F., Rokach, L. & Shapira, B. (2010) *Recommender Systems Handbook*. New York: Springer.

Sarwar, B., Karypis, G., Konstan, J. & Riedl, J. (2001) ‘Item-based collaborative filtering recommendation algorithms’, *Proceedings of the 10th International Conference on World Wide Web*, pp. 285–295.

Schafer, J. B., Konstan, J. & Riedl, J. (2001) ‘E-commerce recommendation applications’, *Data Mining and Knowledge Discovery*, 5(1-2), pp. 115–153.

Stalidis, G., Karapistolis, D. & Vafeiadis, A. (2023) ‘Recommendation systems for e-shopping: Review of techniques for retail and sustainable marketing’, *Sustainability*, 15(8), 6621.

Tam, K. Y. & Ho, S. Y. (2006) ‘Understanding the impact of web personalization’, *MIS Quarterly*, 30(4), pp. 865–890.

Tejeda-Lorente, A., Porcel, C., Bernabé-Moreno, J. & Herrera-Viedma, E. (2018) ‘Adapting recommender systems to the new data privacy regulations’, *Proceedings of the 17th International Conference on Intelligent Software Methodologies, Tools and Techniques (SoMeT 2018)*, pp. 373–385.

The Ledger (2023) ‘Spotify finished 2022 with more than 100 million tracks in its catalog’, *Billboard*, 4 February

Touvron, H., Lavril, T., Izacard, G., Martinet, X., Lachaux, M. A., Lacroix, T., Rozière, B., Goyal, N., Hambro, E., Azhar, F., Rodriguez, A., Joulin, A., Grave, E. and Lample, G. (2023) 'LLaMA: Open and Efficient Foundation Language Models', *arXiv preprint arXiv:2302.13971*.

Wang, X., He, X., Wang, M., Feng, F. & Chua, T. S. (2021) ‘Multimodal Recommender Systems: A Survey’, *ACM Computing Surveys*, 54(1), pp. 1–38.
Xiao, B. & Benbasat, I. (2007) ‘E-commerce product recommendation agents’, *MIS Quarterly*, 31(1), pp. 137–209.
Zhang, Y. & Chen, X. (2020) ‘Explainable Recommendation: A Survey and New Perspectives’, *Foundations and Trends in Information Retrieval*, 14(1), pp. 1–101.
Zhang, S., Yao, L., Sun, A. & Tay, Y. (2019) ‘Deep learning based recommender system: A survey and new perspectives’, *ACM Computing Surveys*, 52(1), pp. 1–38.

Β. ΕΛΛΗΝΙΚΗ

Γκουτζιούρη, Στ. (2013). Εξόρυξη Δεδομένων Χρήσης για Συστήματα Συστάσεων [Διπλωματική εργασία, Αριστοτέλειο Πανεπιστήμιο Θεσσαλονίκης Διατμηματικό Πρόγραμμα Μεταπτυχιακών Σπουδών «Πληροφορική και Διοίκηση» Τμημάτων Πληροφορικής Και Οικονομικών Επιστήμων]. ΙΚΕΕ.
Σκουμπερδής, Μ. (2016). Σχεδίαση και ανάπτυξη κινητής εφαρμογής παροχής εξατομικευμένων συστάσεων τουριστικού περιεχομένου [Διπλωματική εργασία, Πανεπιστήμιο Μακεδονίας, Τμήμα Εφαρμοσμένης Πληροφορικής]. ΨΗΦΙΔΑ